UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE FÍSICA DE SÃO CARLOS

MARCO ANTONIO ALVES DE SOUZA

**Deposição de materiais metálicos em pó a laser baseado em
controle por visão computacional e aprendizagem de máquina**

São Carlos

2019

MARCO ANTONIO ALVES DE SOUZA

**Deposição de materiais metálicos em pó a laser baseado em
controle por visão computacional e aprendizagem de máquina**

Dissertação apresentada ao Programa de Pós-Graduação em Física do Instituto de Física de São Carlos da Universidade de São Paulo, para obtenção do título de Mestre em Ciências.

Área de concentração: Física Aplicada
Opção: Física Computacional

Orientador: Prof. Dr. Jarbas Caiado de Castro Neto

Versão Corrigida

(versão original disponível na Unidade que aloja o Programa)

São Carlos

2019

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Souza, Marco Antonio Alves de

Deposição de materiais metálicos em pó a laser baseado em controle por visão computacional e aprendizagem de máquina / Marco Antonio Alves de Souza; orientador Jarbas Caiado de Castro Neto - versão corrigida -- São Carlos, 2019.

163 p.

Dissertação (Mestrado - Programa de Pós-Graduação em Física Aplicada Computacional) -- Instituto de Física de São Carlos, Universidade de São Paulo, 2019.

1. Visão computacional. 2. Aprendizagem de máquina. 3. Laser Cladding. I. Castro Neto, Jarbas Caiado de, orient. II. Título.

*Aos meus pais, com admiração e gratidão por terem
plantado esta semente o qual tem dado frutos como a
concretização deste primoroso trabalho. E aos meus
irmãos pela amizade incondicional e companheirismo nos
momentos oportunos.*

AGRADECIMENTOS

A Deus em primeiro lugar por dar-me a oportunidade de contemplar seus desígnios na Ciência.

Ao Prof. Dr. Jarbas C. de Castro Neto, que neste período de convivência, orientou-me e contribuiu enormemente para meu crescimento científico e intelectual.

Às professoras Dra. Luciana de Matos e Dra. Fátima Maria Mitsue Yasuoka juntamente com o Dr. André Orlandi de Oliveira, a Dra. Fernanda Rossi Paolillo e o Dr. Luís Gustavo Sabino pelo incentivo que deram à minha entrada para o programa de pós-graduação.

Ao prof. Dr. Alessandro Fraga Farah pelo apoio técnico e sugestões despendidas ao projeto.

Aos alunos de iniciação científica que deram sua contribuição para este projeto de pesquisa: Andrade Tavares Junior, Felipe Capobianco da Silva Passos, Kevin Felipe Kühl Oliveira, Luiz Miyazaka, Matheus Diego da Silva e William Koji Yonamine.

Aos pós-graduandos Vicente Mattos e Lucas Orlandi pelas dicas valiosas empregadas nesta empreitada.

A todos os alunos de iniciação que frequentam ou frequentaram o mesmo espaço de Laboratório. Obrigado pelas boas conversas, risadas e aprendizado mútuo.

Aos ex-alunos João Fernando Ribeiro, Karin Targas e Ramon Sanches pela amizade nascida neste período.

Ao Instituto de Física de São Carlos, pela oportunidade de realização do curso de mestrado.

Ao Laboratório de Inovações Optrônicas para Oftalmologia e Agricultura (LIO²A), por colocar à disposição o espaço necessário para os experimentos bem como os recursos e ferramentas de laboratório utilizados.

À empresa Br-Labs Tecnologia Óptica e Fotônica pelo apoio financeiro e fornecimento de equipamentos e materiais especiais imprescindíveis à pesquisa realizada.

E a todos que direta ou indiretamente contribuíram para a realização de mais esta etapa de minha trajetória. Meus cumprimentos de MUITO OBRIGADO!!!

*“O conhecimento serve para encantar as
pessoas, não para humilhá-las. ”*

Mário Sérgio Cortella

RESUMO

SOUZA, M. A. A. **Deposição de materiais metálicos em pó a laser baseado em controle por visão computacional e aprendizagem de máquina**. 2019. 163 p. Dissertação (Mestrado em Ciências) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2019.

O emprego de lasers no processamento de materiais vem despertando o interesse ante as promissoras e inovadoras aplicabilidades desta tecnologia. Neste contexto, o processo de deposição de materiais metálicos em forma de pó em superfícies alvo mediante fusão a laser ou simplesmente *Laser Cladding*, como é mais conhecido, tem recebido um papel de destaque, principalmente pela sua versatilidade de aplicações no disruptivo campo da Manufatura Aditiva. O procedimento permite, como exemplo, tratar e recuperar superfícies metálicas dos mais variados tipos, processo este de grande interesse para diversos ramos da indústria que o utilizam com o intuito de melhorar a performance ou reparar superfícies danificadas de componentes ou partes mecânicas. No entanto, tópicos de extrema importância relativos à utilização desta técnica são o controle preciso e os relevantes custos envolvidos no processo, fatores cruciais para lograr os resultados esperados. Sob tal perspectiva e no que tange, principalmente, a esta última condição, este trabalho apresenta a adoção de um controle inteligente para o sistema baseado em modernos algoritmos de visão computacional e aprendizagem de máquina, capazes de avaliar as superfícies a serem trabalhadas visando aplicações otimizadas e customizadas. Imagens capturadas da superfície são processadas pelo sistema conduzindo à identificação de determinados padrões (defeitos, formas e desenhos) direcionando o processo de deposição conforme tais peculiaridades detectadas e as necessidades ora requeridas. Implementou-se um sistema de bancada baseado em mecanismo de coordenadas XYZ que integra os sistemas de pulverização de pó, elétrico, óptico e o controle embarcado desenvolvido, além de uma fonte de raio laser infravermelho de média potência. Análises por inspeção visual direta e microscopia óptica foram realizadas em amostras metálicas cujas superfícies, dotadas de diversos padrões ou defeitos incrustados, receberam de forma personalizada depósitos de ligas metálicas em pó compatíveis com o substrato, demonstrando o potencial da aplicação desenvolvida.

Palavras-chave: Visão computacional. Aprendizagem de máquina. *Laser Cladding*.

ABSTRACT

SOUZA, M. A. A. **Laser powder metal deposition control based on computer vision and machine learning**. 2019. 163 p. Dissertação (Mestrado em Ciências) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2019.

Laser materials processing has attracted the interest in view of the promising and innovative applications of this technology. In this context, the process of welding powdered metal materials on target surfaces by laser melting, better known as Laser Cladding, has been given a prominent role, mainly due to its versatility of applications in the disruptive field of Additive Manufacturing. The procedure allows, for example, to treat and recover metal surfaces of the most varied types, a process of great interest to several branches of the industry which use it in order to improve performance or repair damaged surfaces of components or mechanical parts. However, extremely important topics related to the use of this technique are the precise control and relevant costs involved in the process, crucial factors to achieve the expected results. From such a perspective and especially in reference to the latter condition, it is presented herein the adoption of an intelligent control for the cladding system rested on modern algorithms of computer vision and machine learning, capable to evaluate the surfaces to be worked for optimized and customized applications. Captured images from the surface are processed by the system leading to the identification of certain patterns (defects, shapes and designs) driving the deposition process according to such detected peculiarities and the required aims. It was implemented a bench system based on a XYZ coordinate mechanism, which integrates the powder feed, electric, optical and embedded control systems developed, as well as a medium-power infrared laser source. Analyzes by direct visual inspection and optical microscopy were performed on metallic samples whose surfaces, endowed with various patterns or inlaid defects, received deposits of powdery alloys compatible with the substrate in a personalized way according to the detected characteristics, demonstrating the potential of the developed application.

Keywords: Computer vision. Machine learning. Laser cladding.

LISTA DE FIGURAS

Figura 2.1 -	Esquema do processo de Estereolitografia utilizado para manufatura e prototipagem rápida.	34
Figura 2.2 -	Esquema do processo de Fabricação Aditiva baseado no método de Fusão de Leito de Pó.	35
Figura 2.3 -	Esquema do processo de Fabricação Aditiva a Laser na Deposição Direta a Laser ou Laser Cladding. (a) Injeção por pó metálico; (b) Injeção por filamento de metal.	36
Figura 2.4 -	Descrição dos fenômenos físicos termais durante o processo de Laser Cladding.	37
Figura 2.5 -	Densidade de potência versus tempo de interação para processos de materiais a laser. A linha vermelha representa processos usando lasers convencionais (em torno de $1\text{kJ}/\text{cm}^2$). A linha verde estabelece o limiar de fusão dos metais. O gráfico apresenta valores de "distâncias-luz" em relação aos processos de materiais usuais a laser (Da mesma maneira que distâncias muito longas podem ser expressas em anos-luz, pode-se expressar tempos muito curtos em "distâncias-luz", ou seja, a distância que o fóton percorre durante esse curto período correspondente à largura do pulso do laser).	39
Figura 2.6 -	Esquema de alimentadores de pó. (a) Sistema baseado na força da gravidade; (b) Rosca mecânica transportadora; (c) Alimentação por sistema de fluido; (d) Baseado em sistema de vibração.	42
Figura 2.7 -	Esquema do modelo de injeção de pó lateral.	43
Figura 2.8 -	Bocal de injeção de pó coaxial discreto (três vias).	44
Figura 2.9 -	Bocal de injeção de pó coaxial contínuo.	45
Figura 2.10 -	Sistema de Laser Cladding dotado com controle de posicionamento XYZ.	47
Figura 2.11 -	Sistema de Laser Cladding baseado em braço robótico dotado com seis eixos de movimentação.	47
Figura 2.12 -	Esquema de um sistema de DML por injeção de pó cujo controle é em malha aberta.	50
Figura 2.13 -	Esquema de um sistema de DML por injeção de pó cujo controle é em malha fechada.	51
Figura 2.14 -	Diagrama de blocos de um sistema de controle completo de DML discriminando a parte de malha aberta e a de malha fechada.	51
Figura 2.15 -	Comparação entre dois processos de construção de camadas sucessivas por DML. Imagem superior: controle por malha aberta. Imagem Inferior: controle por malha fechada.	52
Figura 2.16 -	Seção transversal de uma camada depositada sobre um substrato. W_c : largura; H_c : altura; A_c : área depositada; A_b : área diluída ou fundida.	53
Figura 2.17 -	Sistema de DML empregando controle em malha fechada. Foi utilizado uma câmera como elemento de sensoramento.	54
Figura 2.18 -	Morfologia de partículas de pó (liga de níquel) utilizadas em processos de Laser Cladding.	55

Figura 2.19 -	Diagrama de Resistência à abrasão versus Resistência à temperatura versus Resistência ao Impacto para algumas ligas mais utilizadas em processos de Laser Cladding.....	56
Figura 2.20 -	Restauração de eixo mecânico utilizando Laser Cladding.	58
Figura 3.1 -	A visão computacional como intersecção de múltiplas áreas científicas.	60
Figura 3.2 -	Etapas de um sistema de visão computacional.....	61
Figura 3.3 -	Exemplos de realce de imagens utilizando técnicas de transformações de intensidade. (a) Esq.: Imagem original; Dir.: Imagem Negativa. (b) Esq.: Imagem original; Dir.: Resultado do alargamento de contraste. (c) Esq.: Imagem escura original; Dir.: Histograma da imagem. (d) Esq.: Imagem original equalizada; Dir.: Histograma equalizado da imagem.	64
Figura 3.4 -	Exemplos de aplicação com filtros espaciais. (a) Esq.: Imagem original de microscopia de revestimento metalúrgico; Dir.: Resultado da aplicação de filtro de suavização. (b) Esq.: Imagem original de uma fratura cerâmica; Dir.: Resultado da aplicação de filtro de aguçamento.	64
Figura 3.5 -	Suavização do efeito de meio-tom em uma imagem estampada utilizando técnica de meio-tom. (a) Imagem original. (b) Espectro de Fourier (aplicação do filtro tipo top-hat). (c) Resultado final.	65
Figura 3.6 -	Mecanismo para a detecção de pontos, linhas e bordas numa imagem: utiliza-se cálculos de derivada para os níveis de intensidade identificando as transições abruptas. (a) Imagem contendo objetos sólidos, uma linha e um ponto de ruído interno. (b) Perfil de intensidade horizontal na altura central da imagem passando pelo referido ponto.	66
Figura 3.7 -	Segmentação baseada em limiarização global ótima utilizando o método de Otsu que trabalha com a maximização da variância entre classes. (a) Imagem ruidosa original. (b) Histograma original. (c) Resultado da limiarização. (d) Imagem original submetida à filtragem. (e) Histograma da imagem suavizada. (f) Resultado final.....	67
Figura 3.8 -	Demonstração dos efeitos produzidos pelos operadores morfológicos Erosão, Dilatação, Abertura e Fechamento. Notar que que as duas últimas operações são combinações das duas primeiras, sendo a ordem de aplicação determinante para o resultado final.	69
Figura 3.9 -	Métricas utilizadas para caracterização de atributos em imagens. (a) Esq.: Imagens de filme exposto ao raio X, onde a densidade e posição das linhas são utilizadas para mensurar a estrutura cristalina de um dado material. Dir.: Plotagem da média das intensidades dos pixels ao longo da vertical para as imagens superior e inferior e a subtração entre elas, permitindo análise mais acurada. (b) Esq.: Imagem de grãos de arroz. Centro: Cores atribuídas às imagens segmentadas de acordo com o ângulo dos grãos detectados. Dir.: Distribuição dos grãos conforme os respectivos ângulos. Obs.: os grãos da borda não são levados em conta pelo algoritmo. (c) Esq.: Imagem de microscopia eletrônica de uma amostra de liga de aço com os grãos coloridos de acordo com o elemento químico presente. Dir.: Plotagem da frequência de distribuição do número de grãos vizinhos.	70

Figura 3.10 -	Exemplos de técnicas de reconhecimento de padrões. (a) Método de Correlação: envolve varrer as áreas de interesse da imagem realizando uma comparação pixel a pixel e computando a soma de diferenças ou outra função de comparação. No exemplo ilustrado, a letra “E”, alvo de reconhecimento, é combinada com cada template ou padrão armazenado em memória (caracteres “A-E” formados por pixels pretos contrastados com fundo branco) empregando uma função de OU-exclusivo de modo a contar o número de pixels que casam e aqueles que não. De todas as comparações, aquela cujo cálculo da diferença entre o total de pixels casados e os não casados possua maior valor positivo resulta na identificação do caractere. (b) Método de reconhecimento facial Haar-like: baseado no algoritmo de Viola-Jones, ⁸³ trata-se de utilizar um conjunto de padrões retangulares compostos de pixels claros e escuros em determinadas proporções para investigar objetos padrões em uma imagem por meio de variações de luminosidade em diferentes direções e amplitudes. A face humana possui elementos característicos como os olhos, nariz e boca que podem ser identificados com o retângulo apropriado.....	72
Figura 4.1 -	Mecanismo de classificação baseado em SVM. (a) Exemplos de possíveis hiperplanos passíveis de separar os dois conjuntos de dados destacados. (b) Hiperplano ótimo que maximiza a margem de separação entre os dados.	78
Figura 4.2 -	Exemplo de aplicação SVM utilizando classificação com margem suave sobre 20 amostras não linearmente separáveis. (a) Parâmetro $C = 10$. (b) Parâmetro $C = 0,1$. As fronteiras de decisão de ambos os casos (linha cheia) são praticamente idênticas. Em contrapartida, as margens (região definida entre as linhas tracejadas) são bem diferentes: um pequeno C estabelece uma região maior permitindo abrangendo mais vetores de suporte.	79
Figura 4.3 -	Aplicação SVM para dados linearmente inseparáveis. (a) Espaço original dos dados de entrada mostrando as classes as quais não são linearmente separáveis. (b) Resultado do mapeamento não linear efetuada pela função kernel (Φ) do espaço de entrada para o novo espaço de características no qual as duas classes são agora linearmente separáveis.	80
Figura 4.4 -	Rede neural simples baseada em unidade perceptron de camada única, onde: $[x_1, x_2, \dots, x_n]$ são os sinais de entrada, $[w_1, w_2, \dots, w_n]$ são os pesos sinápticos, b é um limiar de deslocamento linear e $f(z)$ é uma função de ativação. Um somador combina os valores da multiplicação de cada entrada (x_i) por um peso (w_i) com o valor de bias (b) de forma ponderada, gerando um sinal de ativação (z) que ao passar por uma função de ativação (utilizada para limitar a saída do neurônio) resulta na saída (y).	82
Figura 4.5 -	Estrutura de uma rede neural artificial perceptron multicamadas.	83
Figura 4.6 -	Arquitetura de uma rede neural convolucional (CNN). Neste exemplo a rede é utilizada para classificar dígitos escritos à mão. A entrada da rede é uma imagem de $28 \times 28 \times 1$ (altura, largura, profundidade) a qual passa por duas convoluções utilizando filtros de $5 \times 5 \times 1$ com as suas respectivas camadas de pooling 2×2 , resultando em um conjunto	

	final de mapas de atributos que são então comprimidas em um único vetor perfazendo a entrada de uma rede neural densa (totalmente conectada).	85
Figura 4.7 -	Exemplo de um processo de convolução em uma CNN. Um kernel de 2x2 desliza sobre a matriz que representa os valores de uma imagem de 3x3, computando o resultado da soma dos produtos ponto a ponto. O resultado final é uma matriz reduzida contendo um mapa de características da imagem original.	86
Figura 4.8 -	Exemplo de um processo de uma camada de pooling em uma CNN. Um kernel de 2x2 desliza sobre a matriz de uma imagem 4x4 (o mapa de característica obtida pela camada de convolução) computando o maior valor (comumente chamada de maxpooling) contido na área abrangida pela sobreposição das matrizes numa nova matriz de atributos. A redução da dimensionalidade neste processo é bastante notável.	86
Figura 5.1 -	Arranjo experimental do sistema de deposição de materiais metálicos desenvolvido para o projeto.	90
Figura 5.2 -	Sistema de movimentação XYZ desenvolvido para o sistema de deposição do projeto.	92
Figura 5.3 -	Fonte de raio Laser utilizado no projeto (modelo 70W EP-Z Pulsed Fiber Laser G4 da SPI Lasers®).	93
Figura 5.4 -	Esquema do efeito de Venturi adotado para o sistema de alimentação e injeção de pó do projeto.	94
Figura 5.5 -	Válvula geradora de vácuo responsável por realizar o transporte do pó do alimentador ao injetor do sistema.	95
Figura 5.6 -	Sistema de fornecimento de gás para o sistema de deposição (Cilindro de gás Argônio montado com registro de abertura principal, secundário, manômetros e válvula de segurança).	96
Figura 5.7 -	Aparato de alimentação de pó desenvolvido para o sistema de deposição.	97
Figura 5.8 -	Bico injetor de pó metálico tipo lateral do sistema de deposição desenvolvido.	98
Figura 5.9 -	Placa de controle modelo Raspberry Pi 3 utilizada no projeto.	99
Figura 5.10 -	Módulo de câmera empregada pela placa de controle Raspberry Pi 3.	100
Figura 5.11 -	Sistema de iluminação com a câmera da Raspberry Pi 3 embutida.	101
Figura 5.12 -	Sensor de distância a laser selecionado para o projeto (modelo HG-C1100 da Panasonic®).	102
Figura 5.13 -	Diagrama elétrico do sistema de deposição a laser.	103
Figura 5.14 -	Gabinete elétrico do sistema de deposição do projeto.	104
Figura 5.15 -	Interface gráfica desenvolvida para o sistema de deposição de materiais a laser.	106
Figura 5.16 -	Fluxograma do método de controle desenvolvido.	107
Figura 5.17 -	Ajuste da distância ótima de operação (foco do raio laser incidente) entre o cabeçote de deposição e a superfície da peça a receber o depósito utilizando um preciso sensor de distância a laser.	108
Figura 5.18 -	Campo de visão da área de trabalho do sistema a partir da câmera da Raspberry Pi instalada no cabeçote de deposição. Neste exemplo, observa-se a captura da imagem de uma régua esquadro assentada sobre a plataforma para uma simples referência.	109

Figura 5.19 -	Seleção (via mouse) da região da peça candidata a receber o depósito. A área passará pela análise do software que determinará em quais subáreas será realizado o processo.	110
Figura 5.20 -	Resultados do processo de filtragem em imagens utilizando os dois tipos de filtros selecionados para o projeto. (a) Imagem original. (b) Filtro <i>NonLocalMeans</i> . (c) Filtro <i>Gabor</i>	111
Figura 5.21 -	Algumas das imagens contendo determinados padrões (logo de empresa, orifício e <i>QR Code</i>) as quais foram utilizadas para o treinamento dos algoritmos de detecção produzidos para o projeto.	113
Figura 5.22 -	Aplicativo Imglab utilizado para anotação de objetos de interesse em imagens para treinamento dos algoritmos de aprendizagem de máquina.	114
Figura 5.23 -	Testes de detecção de padrões característicos selecionados para o projeto em imagens aleatórias utilizando os algoritmos treinados obtidos.	114
Figura 5.24 -	Imagens (200x200, escala de cinza) de superfícies metálicas (aço) apresentando seis tipos de defeitos típicos após o processo de fabricação (processo de laminação).	116
Figura 5.25 -	Janela da interface da ferramenta TensorBoard apresentando informações em tempo real sobre o processo de treinamento da rede neural convolucional utilizada para a criação do detector.	118
Figura 5.26 -	Imagens de superfícies metálicas com defeitos testadas pelo detector baseado em CNN elaborado para o projeto.	119
Figura 5.27 -	Esboço da trajetória de deposição do sistema desenvolvido em relação às coordenadas XYZ.	122
Figura 5.28 -	Algumas das amostras metálicas (substratos de aço e alumínio de diferentes tipos) utilizadas no projeto.	124
Figura 6.1 -	Imagem de amostra de aço 430 captada pela câmera do sistema de deposição. Observa-se em sua superfície algumas áreas degradadas como manchas e gravações feitas a laser, além de oxidações.	127
Figura 6.2 -	Defeitos detectados na superfície da amostra pelo algoritmo do programa desenvolvido.	128
Figura 6.3 -	Imagem da amostra de aço 430 mostrando a região selecionada (quadrante em azul) via software desenvolvido para o projeto na qual o sistema realizará o depósito.	128
Figura 6.4 -	Mapa de trajetória em termos de pixels gerado pelo software (a deposição ocorrerá na área em preto).	129
Figura 6.5 -	Processo de deposição realizada pelo sistema na área selecionada da amostra de aço 430.	129
Figura 6.6 -	Resultado final do processo de deposição realizado na amostra de aço 430. Observa-se que a fina camada aplicada não foi suficiente para cobrir todos os defeitos presentes na superfície da amostra.	130
Figura 6.7 -	Imagem de microscopia óptica mostrando detalhes da área (região de um dos cantos) depositada na amostra de aço 430.	130

Figura 6.8 -	Resultado da deposição de pó metálico Colmonoy 63 sobre a superfície de uma amostra de aço 304.	131
Figura 6.9 -	Resultado da deposição de pó metálico Durmat 60 AH sobre a superfície de uma amostra de aço SAE-8620.	132
Figura 6.10 -	Imagem porca tipo T fabricada em aço carbono SAE-1020 (Dimensões aproximadas - Largura x Altura x Profundidade: 19x10x9mm).	133
Figura 6.11 -	Região selecionada via software correspondendo a uma das faces da porca.	134
Figura 6.12 -	Mapa de trajetória gerado pelo sistema. Um objeto circular (identificado em branco) foi detectado pelo software desenvolvido ao pesquisar a área previamente selecionada da imagem (delimitada em preto).	134
Figura 6.13 -	Imagem mostrando o processo de deposição de pó metálico sobre a superfície de uma das faces da porca tipo T utilizada nos experimentos.	135
Figura 6.14 -	Resultado da deposição de liga de aço inox 316L sobre a face de uma porca tipo T. Área depositada aproximada: 1,3cm ² . Camada depositada (altura): 0,1mm. Parâmetros utilizados pelo laser: CW, 20W.	135
Figura 6.15 -	Detalhes em imagem de microscopia da deposição de pó metálico sobre porca tipo T.	136
Figura 6.16 -	Imagem amostra de aço SAE-8620 (Dimensões aproximadas - Largura x Altura x Profundidade: 80x42x9mm) apresentando uma gravação de logomarca em sua superfície.	137
Figura 6.17 -	Área selecionada da superfície da amostra de aço SAE-8620 apta para a análise realizada pelo software e passível de deposição.	137
Figura 6.18 -	Filtragem da Imagem da região selecionada. (a) Imagem normal; (b) Imagem tratada por filtro (NML).	138
Figura 6.19 -	Objeto detectado na imagem. Neste caso, uma logomarca que o algoritmo desenvolvido foi treinado para reconhecer em imagens.	138
Figura 6.20 -	Mapa de trajetória gerado pelo sistema. A área em branco refere-se ao logotipo identificado pelo software desenvolvido ao pesquisar a área previamente selecionada da imagem (delimitada em preto).	139
Figura 6.21 -	Resultado da deposição de liga de aço inox 316L em pó sobre a face de uma amostra de aço SAE-8620. Área depositada total (aproximadamente): 13,5cm ² . Camada depositada (altura): 0,1mm. Parâmetros utilizados pelo laser: CW, 20W.	139
Figura 6.22 -	Imagem captada pela câmera do sistema referente à amostra de chapa de aço 316L (Dimensões aproximadas - Largura x Altura x Profundidade: 191x100x4mm) apresentando uma gravação de <i>QR Code</i> em sua superfície.	140
Figura 6.23 -	Área selecionada da superfície da amostra de aço 316L apta para análise do software e passível de deposição.	141
Figura 6.24 -	<i>QR Code</i> detectado na imagem captada pela câmera do sistema.	141
Figura 6.25 -	Mapa de trajetória gerado pelo sistema. A área abrangendo o <i>QR Code</i> (identificado em branco) será poupado do processo de revestimento ao contrário do restante da área pesquisada pelo software (em preto).	142

Figura 6.26 -	Resultado da deposição de liga de aço inox sobre uma área em torno de um <i>QR Code</i> presente na superfície de uma chapa de aço 316L. Área depositada aproximada: 11,8cm ² . Camada depositada (altura): 0,15mm. Parâmetros utilizados pelo laser: CW, 25W.....	142
Figura 6.27 -	Carcaça de um dispositivo eletrônico fabricado em alumínio (Dimensões aproximadas - Largura x Altura x Profundidade: 68x40x17mm).	143
Figura 6.28 -	Área selecionada da superfície da carcaça metálica (imagem superior) apta à análise pelo software. Este detectou um padrão circular na região gerando o mapa de trajetória (imagem inferior).	144
Figura 6.29 -	Resultado do depósito de sucessivas camadas de pó de alumínio sobre uma região circular, reconhecida pelo sistema de detecção desenvolvido, presente na superfície de uma carcaça metálica, caracterizando a reconstrução de uma parte danificada Diâmetro x Altura: 3,5x4,5mm). Parâmetros utilizados pelo laser: Pulsado, 30W (o alumínio possui a característica de refletir mais a luz do laser utilizado quando comparado ao aço; por essa razão mais energia deve ser fornecida ao processo e isso se obtém utilizando o laser no modo de pulsos os quais possuem alta energia).	145
Figura 6.30 -	Imagem captada pela câmera do sistema referente a uma chapa de aço 304 apresentando em sua superfície três pronunciadas fendas (Dimensões aproximadas - Largura x Altura x Profundidade: 160x85x5mm).	146
Figura 6.31 -	Área selecionada da superfície de chapa de aço 304 apta para análise do software e passível de deposição. Observa-se a presença de três ranhuras dentro destes limites.	147
Figura 6.32 -	Imagem da região selecionada da superfície de chapa de aço 304 tratada pelo sistema através de filtros (à esquerda). Defeitos (ranhuras) detectados pelo software (à direita).	147
Figura 6.33 -	Mapa de trajetória gerado pelo sistema. A área abrangendo as ranhuras (identificado em branco) será o alvo do processo de revestimento em detrimento do restante da área selecionada (em preto).....	148
Figura 6.34 -	Processo de deposição de pó metálico sobre as fendas detectadas pelo software na superfície de uma chapa de aço 304. O tempo total da operação foi de aproximadamente seis horas.	148
Figura 6.35 -	Resultado do depósito de liga de aço inox em pó sobre as fendas detectadas pelo software na superfície de uma chapa de aço 304. Área total depositada (aproximadamente): 3,5cm ² . Parâmetros utilizados pelo laser: CW, 20W.....	149
Figura 6.36 -	Detalhes em imagem de microscopia da deposição de pó metálico sobre uma região de uma das fendas preenchidas no processo (uma das extremidades).	149

LISTA DE TABELAS

Tabela 1 -	Principais Especificações do Laser modelo 70W EP-Z Pulsed Fiber Laser G4 da SPI Lasers.	94
Tabela 2 -	Especificação dos padrões característicos selecionados para o projeto e os respectivos treinamentos.	113
Tabela 3 -	Possíveis resultados da detecção e respectivas ações a serem tomadas.....	120
Tabela 4 -	Principais parâmetros utilizados pelo sistema de deposição durante os testes.	125

LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Network</i>
ASTM	<i>American Society for Testing and Materials</i>
CAD	<i>Computer Aided Design</i>
CAM	<i>Computer Aided manufacturing</i>
CCD	<i>Charge-coupled Device</i>
CMOS	<i>Complementary Metal-oxide Semiconductor</i>
CNN	<i>Convolutional Neural Network</i>
DML	Deposição Direta de Metais a Laser
HSI	<i>Hue-Saturation-Intensity</i>
IA	Inteligência Artificial
IR	<i>Infrared Radiation</i>
ISO	<i>International Organization for Standardization</i>
KNN	<i>K-nearest-neighbor</i>
Nd:YAG	<i>Neodymium-doped Yttrium Aluminium Garnet</i>
NLM	<i>Nom-Local Means filter</i>
OCR	<i>Optical character recognition</i>
PID	<i>Proportional-integral-derivative Controller</i>
RGB	<i>Red-Green-Blue</i>
RNN	Redes Neurais Artificiais
ROI	<i>Region of Interest</i>
SLA	<i>Stereolithography Apparatus</i>
SLM	<i>Selective Laser Melting</i>
SLS	<i>Selective Laser Sintering</i>
SVM	<i>Support Vector Machine</i>
3D	Três dimensões – espaço tridimensional

SUMÁRIO

1	INTRODUÇÃO	29
1.1	Motivação	30
1.2	Objetivos da Pesquisa	31
1.3	Estrutura do Trabalho	31
2	MANUFATURA ADITIVA A LASER	33
2.1	Classificação	33
2.1.1	Foto-polimerização	34
2.1.2	Fusão de Leito de Pó	35
2.1.3	Deposição Direta a Laser	36
2.2	Laser Cladding	37
2.2.1	Estruturas Envolvidas	38
2.2.1.1	Laser	38
2.2.1.2	Conjunto Alimentador e Injetor de Pó	40
2.2.1.3	Dispositivo de Posicionamento	45
2.2.1.4	Controle e Sensoriamento	48
2.2.2	Materiais e Insumos	54
2.2.3	Aplicações	56
3	VISÃO COMPUTACIONAL	59
3.1	Definição	59
3.2	Processos Envolvidos	61
3.2.1	Aquisição de Imagem	62
3.2.2	Pré-processamento	63
3.2.3	Segmentação	65
3.2.4	Extração de Atributos	69
3.2.5	Reconhecimento e Base de Conhecimento	71
4	APRENDIZAGEM DE MÁQUINA	73
4.1	Contexto	73
4.2	Tipos de Aprendizagem de Máquina	74

4.3	Algoritmos Notáveis	76
4.3.1	Máquinas de Vetores de Suporte (SVM)	77
4.3.2	Aprendizagem Profunda	80
4.3.2.1	Redes Neurais Artificiais (RNA)	81
4.3.2.2	Redes Neurais Convolucionais (CNN)	83
5	MATERIAIS E MÉTODOS	89
5.1	Classificação e Delimitações da Pesquisa	89
5.2	Arranjo Experimental	90
5.2.1	Sistema de Posicionamento	91
5.2.2	Fonte de Raio Laser	93
5.2.3	Sistema de Injeção de Pó	94
5.2.4	Controle do Sistema (Hardware)	99
5.2.5	Montagem Elétrica	102
5.3	Software de Controle do Sistema	104
5.3.1	Ferramentas Computacionais Adotadas	104
5.3.2	Método de Controle Inteligente Desenvolvido	106
5.3.2.1	Posicionamento da Área de Trabalho e Captura da Imagem	108
5.3.2.2	Seleção da Região Desejada e Pré-processamento da Imagem	109
5.3.2.3	Extração de Padrões da Imagem	111
5.3.2.3.1	Deteção de padrões específicos na superfície empregando SVM	112
5.3.2.3.2	Deteção de defeitos na superfície da amostra empregando CNN	115
5.3.2.4	Averiguação da Deteção e Escolha da Melhor Estratégia	119
5.3.2.5	Geração do Mapa de Trajetória	121
5.3.2.6	Execução da Deposição	121
5.3.2.7	Finalização do Processo	122
5.4	Amostras e Pós Utilizados	123
5.4.1	Amostras de metais	123
5.4.2	Pós de metais e ligas metálicas	125
5.5	Parâmetros Gerais do Sistema	125
6	RESULTADOS	127
6.1	Depósitos sem Otimização	127

6.2	Depósitos em Regiões com Padrões Detectados	132
6.2.1	Depósito em região com orifício circular	132
6.2.2	Depósito em região com logotipo de empresa	136
6.2.3	Depósito em região com <i>QR Code</i>	140
6.3	Reconstrução de um objeto detectado	143
6.4	Depósito em Regiões com Defeitos Detectados	146
7	CONCLUSÕES	151
	REFERÊNCIAS	153

1 INTRODUÇÃO

Considerada como uma forma altamente concentrada de energia pura e versátil, o laser emergiu como uma ferramenta muito atraente em termos de instrumento de pesquisa e aplicações nos mais variados campos do conhecimento humano. Não por acaso, o emprego dessa tecnologia no ramo da indústria tem sido crescente ao longo das últimas décadas. Desde meados dos anos 70 quando novos e robustos tipos de lasers surgiram, muitas aplicações práticas de processamento de materiais foram incorporadas pelo segmento.¹ A grande quantidade de estudos científicos na área, melhorias crescentes na eficiência e qualidade dos materiais envolvidos na fabricação dos lasers concomitante à redução de seus custos e o avanço do desenvolvimento de sistemas inteligentes de controle baseados em tecnologia de ponta vem contribuindo para o aumento dessa tendência.^{2,18}

Principalmente utilizado em processos de corte, solda e gravação de materiais, o laser vem abrangendo outras formas inovadoras de aplicações apontadas como de grande valia para a indústria tais como a prototipagem rápida, tratamento térmico, micro/nano estruturas de superfícies, micro retífica, limpeza e deposição de materiais variados em substratos diversos.² Tais técnicas apresentam vantagens consideráveis e têm despertado o interesse de muitos setores na aplicabilidade destes métodos cujos processos foram categorizados em um campo genérica e convencionalmente chamada de Manufatura^{*} Aditiva a Laser (do inglês *Laser-Based Additive Manufacturing*).³

A Manufatura Aditiva a Laser é um tema de considerável relevância, sendo vista atualmente como uma inovação de enorme impacto na indústria, sobretudo nesse período de florescência da chamada Indústria 4.0[†].^{4-6,9} Trata-se da utilização do laser em processos de deposição ou fusão de materiais (ligas, metais, cerâmicos, resinas) sobre uma gama de superfícies ou em camadas sucessivas produzindo revestimentos, formas ou objetos 3D variados.⁵ Existem basicamente três vertentes de utilização que englobam esta técnica as quais serão descritas no próximo capítulo. Elas diferem umas das outras quanto aos mecanismos e materiais empregados no processo.⁶ Dentre estas, a Deposição Direta de Metais a Laser (DML), ou simplesmente *Laser Cladding*, como é mais reconhecido, é o método empregado

^{*} O termo “Fabricação” ao invés de “Manufatura” também é encontrado na literatura.

[†] Nomeada também como “quarta revolução industrial”, caracteriza-se por um conjunto de tecnologias que permitem a fusão do mundo físico, digital e biológico. Fonte: <http://www.industria40.gov.br/>

na pesquisa retratada neste trabalho. Trata-se, basicamente, de uma técnica que consiste em fundir materiais metálicos, mormente em forma de pó, em uma camada aderente à superfície de um substrato compatível, utilizando um feixe de laser focalizado.

1.1 MOTIVAÇÃO

Não obstante os benefícios inerentes em utilizar a DML, notadamente a obtenção de propriedades metalúrgicas superiores⁷, um aspecto fundamental que deve ser levado em conta ao tratar do uso dessa tecnologia é o rigoroso e complexo controle dos diversos parâmetros e componentes próprios ao sistema, além da utilização de insumos especiais, fatores extremamente necessários para que todas as vantagens e garantias de qualidade do procedimento tenham efeito. Como consequência, equipamentos que realizam a tarefa, bem como a matéria-prima empregada (ligas metálicas em pó) apresentam, via de regra, custos elevados.⁸

Sistemas usuais de *Laser Cladding* geralmente operam baseados em uma programação pré-definida da área a ser depositada, isto é, permitem realizar deposições localizadas conforme previamente planejadas.⁷⁻⁸ Entretanto, em muitas aplicações é deveras complicado ou custoso estabelecer os locais exatos para receberem os depósitos, seja por uma dificuldade de análise adequada das regiões alvo, falta de um modelo 3D da peça ou por um tempo demasiado de preparação do processo (*setup*)^{*}. Nestas situações, adota-se, como padrão, recobrir uma área maior que a necessária para assegurar o trabalho em prol da produtividade em escala, abdicando de customizações pontuais. Evidentemente, o resultado, em contrapartida, é a geração de desperdício tanto material quanto de tempo[†].

Diante desse cenário é que se introduz este estudo, com a motivação de apresentar uma solução que customize e otimize o processo, tornando-o menos custoso. Nesse sentido, modernas e poderosas ferramentas computacionais disponíveis, decorrentes do enorme campo de estudo da área de Inteligência Artificial (IA), são invocadas para a tarefa. Tal abordagem encontra amparo em muitas pesquisas que demonstram a capacidade da IA em prever, modelar, otimizar e melhorar o desempenho dos principais sistemas de processamento de

^{*} Tempo de preparação e troca de ferramentas em uma máquina, cujo início é definido a partir da última peça produzida na operação anterior, até a primeira peça produzida na operação subsequente. Fonte: <https://www.cimm.com.br/portal/verbetes/exibir/1226-set-up>

[†] Tempo gasto depositando em áreas desnecessárias e em muitos casos, em etapas de acabamento superficial adicional.

materiais a laser.⁹ Entretanto, a maioria dos trabalhos publicados focam apenas no controle da qualidade do processo. Esta pesquisa, por outro lado, prevê a utilização de tais ferramentas modernas como forma de otimizar a produtividade do processo.

1.2 OBJETIVOS DA PESQUISA

Remetendo, como exemplo de aplicação, ao tratamento e recuperação de superfícies metálicas dos mais variados tipos de relevo, processo de grande interesse para diversos ramos da indústria com o objetivo de prevenir desgastes ou reparar superfícies danificadas, este projeto propõe o desenvolvimento de um sistema de bancada capaz de realizar, customizadamente, a deposição de materiais metálicos em forma de pó aspergidos em direção à determinadas superfícies, mediante processo de fusão à alta temperatura despendida pela região focal de um feixe de raio laser incidente.

A partir do protótipo construído o foco do projeto se desenvolve em estabelecer um sistema de controle para o processo de deposição, baseado em algoritmos de visão computacional e aprendizagem de máquina em conjunto com sensoriamento de distância a laser, aptos a avaliar as superfícies de trabalho designadas em busca por determinados padrões desejados e retornar o mapeamento dessas áreas, dando ao sistema condições de proceder a aplicação do revestimento estritamente nos locais necessários.

1.3 Estrutura do Trabalho

Este trabalho está dividido em sete capítulos, além das referências bibliográficas ao final da obra, organizados da seguinte forma:

Neste primeiro capítulo introdutório é exposto um breve panorama do assunto pesquisado, a motivação do trabalho, os objetivos pretendidos e a maneira como o texto é estruturado.

O segundo capítulo apresenta uma revisão bibliográfica dos processos de deposição de materiais, cunhados genericamente como Manufatura Aditiva, pormenorizando o *Laser Cladding*, cujo método fora o adotado nesta pesquisa.

No terceiro capítulo é retratado os principais conceitos de visão computacional e processamento de imagens digitais, úteis ao contexto desse trabalho.

O quarto capítulo, por sua vez, discorre brevemente sobre determinados tópicos de aprendizagem de máquina, focando em métodos empregados no projeto: o clássico algoritmo Máquinas de Vetores de Suporte e o moderno Aprendizado Profundo representado, neste trabalho, pelas Redes Neurais Convolucionais.

A classificação, delimitações e todos os métodos desenvolvidos para a pesquisa, bem como os materiais e insumos utilizados, são descritos no quinto capítulo.

O sexto capítulo contempla os principais resultados do trabalho e suas respectivas análises.

E por fim, o sétimo capítulo aponta as conclusões acerca dos resultados ante os objetivos traçados para a pesquisa, além de pontuar novamente sua importância e estabelecer considerações em termos de trabalhos futuros.

2 MANUFATURA ADITIVA A LASER

A Manufatura Aditiva a Laser se insere dentro de uma ampla categoria denominada simplesmente de Manufatura Aditiva ou Impressão 3D. De acordo com as normas técnicas ISO-17296 e ASTM-F2792, publicadas respectivamente pela Organização Internacional para Padronização (ISO)^{*} e Sociedade Americana para Testes e Materiais (ASTM)[†], a Manufatura Aditiva pode ser definida como um conjunto de tecnologias, alternativas aos métodos de fabricação subtrativas, direcionadas a construir peças tridimensionais por adição ou fusão de camadas de um dado material a partir de um modelo tridimensional assistido por computador (CAD)[‡].^{8,10}

Desenvolvido em meado dos anos 80, a prototipagem rápida foi a primeira forma de utilização da Manufatura Aditiva. A ideia era materializar em escala real e de maneira mais acelerada as ideias que os engenheiros tinham em mente para seus projetos.¹¹ Embora sua existência há praticamente três décadas, apenas mais recentemente a Manufatura Aditiva elevou-se como uma importante tecnologia de fabricação comercial, sendo utilizada para muitos fins.¹²

2.1 Classificação

A Manufatura Aditiva pode ser aplicada a muitas classes de materiais, incluindo metais, polímeros, cerâmicas, compósitos e até mesmo biológicos. O processo exige uma fonte de energia para que os materiais sejam aquecidos, e com isso, aderidos. Neste quesito, vários elementos podem ser utilizados como o laser, feixe de elétrons, arco elétrico, resistência elétrica, etc. Quanto aos aspectos construtivos, vários sistemas têm sido desenvolvidos ao longo do tempo para se adaptarem às necessidades de projeto. Em razão dessa variedade de fatores, a Manufatura Aditiva recebe, por convenção, uma classificação.¹¹⁻

¹²

^{*} Do inglês, *International Organization for Standardization*.

[†] Do inglês, *American Society for Testing and Materials*.

[‡] Do inglês, *Computer Aided Design*.

Considerando a Manufatura Aditiva a Laser, que utiliza uma fonte de raio laser como a fonte de energia, costuma-se, em geral, dividi-la em três categorias distintas, conforme descritas na sequência.

2.1.1 Foto-polimerização

A Figura 2.1 ilustra o processo de Foto-polimerização, mais conhecido por Estereolitografia a Laser (SLA)^{*} no qual as peças são construídas pela ação de varredura de um raio laser em uma cuba montada numa plataforma móvel contendo foto-polímero[†] de resina líquida. O foto-polímero cura e solidifica mediante um comprimento de onda apropriado do laser utilizado, geralmente, na faixa do ultravioleta. No decorrer do processo, guiado por um modelo 3D e transmitido por computador ao sistema, a plataforma de construção é deslocada por uma distância equivalente à espessura da camada. A resina fresca é então espalhada sobre a camada solidificada e o processo é repetido camada por camada até a construção do objeto estar completo.^{6,14}

Figura 2.1 - Esquema do processo de Estereolitografia utilizado para manufatura e prototipagem rápida.

Fonte: Adaptada de COMMONS.¹³

^{*} Do inglês, *Stereolithography Apparatus*. O nome, provém do grego "*stereon*" (sólido), "*lithos*" (pedra) e "*graphy*" (escrita).

[†] Materiais constituídos por grupos fotofuncionais que alteram facilmente sua estrutura química quando expostos a pequenas cargas de energia luminosa. Fonte: <https://www.nitto.com/br/pt/rd/base/control/phpolymer/>

2.1.2 Fusão de Leito de Pó

O processo de Fusão de leito de pó, conhecido como Sinterização Seletiva a Laser (SLS)* ou Fusão Seletiva a Laser (SLM)[†], dependendo dos materiais envolvidos, é um método de impressão 3D que se realiza mediante a sinterização[‡] (primeiro caso) ou fusão (segundo caso) de camadas finas de pó material, o qual está uniformemente espalhado em uma plataforma móvel pré-aquecida. Como exemplificado na Figura 2.2, o feixe de laser, guiado pela seção transversal de um modelo CAD, varre o leito de pó fundindo ou sintetizando o material nessa área especificada e assim criando uma camada do objeto desejado. Através da movimentação da plataforma as camadas subsequentes de pós são sobrepostas em cima das camadas anteriores e fundidas até o objeto 3D ser construído inteiramente. O excesso de pó é então removido manualmente ou por vácuo restando a peça construída que em certos casos pode ser submetida a processos adicionais para resultar nas propriedades mecânicas desejadas.¹⁵

Figura 2.2 - Esquema do processo de Fabricação Aditiva baseado no método de Fusão de Leito de Pó.

Fonte: Adaptada de COMMONS.¹⁶

* Do inglês, *Selective Laser Sintering*. O método utiliza polímeros como o material base do pó.

† Do inglês, *Selective Laser Melting*. Neste caso, o material utilizado são metais em forma de pó.

‡ Processo de aglutinação de partículas sólidas por aquecimento em temperaturas abaixo da temperatura de fusão. Fonte: <https://www.cimm.com.br/portal/verbetes/exibir/1641-sinterizacao>

2.1.3 Deposição Direta a Laser

Na Deposição Direta a Laser, processo que recebe várias denominações sendo o mais comum *Laser Cladding*, o feixe de raio laser é focado na superfície de trabalho produzindo uma massa fundida local. Ao mesmo tempo, um material metálico em forma de pó ou filamento é projetado em direção a este ponto localizado de derretimento através de um bico injetor, tal como esquematizado na Figura 2.3, e como resultado, ocorre a fusão desses materiais junto à superfície.⁶ Ao dotar o bico injetor com capacidade de movimentação no espaço (XYZ, ou mais graus de liberdade) é possível a construção de pistas de revestimentos regulares dando origem a camadas uniformes chamadas de *Cladding*,^{*} as quais podem permitir a construção de geometrias complexas (objetos 3D), se forem devidamente sobrepostas durante o procedimento de revestimento.³

Figura 2.3 - Esquema do processo de Fabricação Aditiva a Laser na Deposição Direta a Laser ou *Laser Cladding*. (a) Injeção por pó metálico; (b) Injeção por filamento de metal.

Fonte: Adaptada de TOYSERKANI.²

Neste trabalho de pesquisa foca-se nessa última categoria de Fabricação Aditiva a Laser apresentada e mais particularmente no processo de deposição que utiliza ligas metálicas em forma de pó, como ilustrado no item (a) da Figura 2.3 acima.

^{*}Termo em inglês que significa “material que cobre a superfície de algo e o protege”.

Fonte: <https://dictionary.cambridge.org/pt/dicionario/ingles/cladding>

2.2 Laser Cladding

Pesquisado há mais de 30 anos com uma extensa literatura a respeito,^{2,19} o processo de deposição de metais a laser baseado no método de *Laser Cladding* pode se estender a diversos ramos de aplicações tendo recebido diferentes denominações ao longo dos anos.^{2,19,20} Contudo, a despeito da variedade de nomes dado a esta técnica, o princípio básico é sempre o mesmo: utilização da fonte de calor concentrada gerada pelo feixe de raio laser de certa potência para derreter localmente uma pequena porção de área superficial do substrato concomitantemente com os materiais adicionados por injeção ou aspersão, proporcionando a criação de uma nova camada de material após um rápido processo de solidificação. A Figura 2.4 descreve, resumidamente, os fenômenos físicos envolvidos no processo de deposição em termos de transferência de calor.

Figura 2.4 - Descrição dos fenômenos físicos termais durante o processo de *Laser Cladding*.
Fonte: Adaptada de BATUT *et al.*²¹

De acordo com Zhong,¹⁹ o foco de um feixe de laser de alta potência pode apresentar uma densidade de potência de até 10^{12} W/cm², podendo aquecer rapidamente uma diminuta área de superfície do metal a uma temperatura acima de 10^5 K, que, em seguida, arrefece-se rapidamente a uma taxa de até 10^7 K/s. Estas características peculiares proporcionam um cenário excelente em termos da capacidade de se produzir tal processo de deposição com alta precisão, qualidade e eficiência.

Considerada uma técnica de caráter multidisciplinar por envolver várias áreas do conhecimento científico, industrial e tecnológico tais como a óptica, fotônica, metalurgia, termodinâmica, mecânica, robótica, controle de sistemas, ciência dos materiais, engenharia de software, entre outras,^{2,19,24-30} a DML lança-se como um sistema robusto e versátil integrando capacidades de movimentação de múltiplos eixos, a possibilidade de trabalho com vários tipos de materiais e a incorporação de sistemas de controle avançados, o que o torna capaz de revestir, construir e reconstruir componentes ou partes de geometrias, desde as mais simples às mais complexas, com integridade e precisão almejavéis.³

2.2.1 Estruturas Envolvidas

Essencialmente, um sistema completo de DML utilizando pó consiste dos seguintes itens: uma fonte de raio laser de potência, um conjunto alimentador de pó com bocal de distribuição e um dispositivo de posicionamento controlado por software, sendo a combinação destas partes um elemento chave para a obtenção de sucesso da aplicação do método.² O desenvolvimento e aprimoramento dessa técnica de deposição a laser remete à própria evolução desses itens estruturais principais que vêm se desenvolvendo graças aos avanços tecnológicos em curso. Na sequência serão detalhadas tais estruturas.

2.2.1.1 Laser

O processo de *Laser Cladding* realiza o derretimento simultâneo de uma área local do substrato e do material a ser depositado. A zona termicamente afetada pela ação do raio laser, a profundidade e largura da camada revestida, a potência do laser e o tempo de interação entre laser e material devem se combinar de tal forma que um mínimo de densidade de potência é necessária para uma ligação adequada dos dois entes fundidos.^{2,25} Com efeito, conforme se

observa pelo mapa da densidade de potência versus tempo de interação de diversos métodos de processamento de materiais a laser apresentado pela Figura 2.5, o processo de *Laser Cladding* exige um certo nível de energia por um dado tempo para ocorrer satisfatoriamente. Uma faixa de valores usual para esses parâmetros aponta $10^2 - 10^4 \text{ W/mm}^2$ de densidade de potência para tempo de interação na ordem de $10^{-3} - 0,5$ segundos.²⁴ Por esta razão, a DML requer o uso de uma fonte de raio laser com densidade de potência apropriada que via de regra remete a lasers de alta potência.²⁵

Figura 2.5 - Densidade de potência versus tempo de interação para processos de materiais a laser. A linha vermelha representa processos usando lasers convencionais (em torno de 1 kJ/cm^2). A linha verde estabelece o limiar de fusão dos metais. O gráfico apresenta valores de "distâncias-luz" em relação aos processos de materiais usuais a laser (Da mesma maneira que distâncias muito longas podem ser expressas em anos-luz, pode-se expressar tempos muito curtos em "distâncias-luz", ou seja, a distância que o fóton percorre durante esse curto período correspondente à largura do pulso do laser).

Fonte: Adaptada de MEIJER.⁴⁸

Há ainda outros fatores não menos importantes a serem considerados como a qualidade do feixe do raio laser utilizado e a reflexão da luz provinda das superfícies metálicas envolvidas no processo de deposição. Sabe-se que a reflexão está relacionada com o comprimento de onda do laser e varia de metal para metal. Além disso, é salutar considerar a contribuição da temperatura no papel de causar alterações neste quesito de refletividade.²

De acordo com Toyserkani,² tanto os lasers pulsados quanto os de onda contínua podem ser utilizados no processo de revestimento a laser. Contudo, é ressaltado que para lasers pulsados é necessário manter o pico de potência de cada pulso em um patamar limitado uma vez que pulsos com alta energia de pico (mesmo aqueles com baixa potência média) podem vaporizar as partículas diminutas do pó antes de atingir a zona de processo.

Uma série de tipos de laser encontra-se disponível no mercado sendo que para a aplicação do processo de *Laser Cladding*, lasers de CO₂ e variações do Nd:YAG são os mais utilizados.² O primeiro desses foram os pioneiros por fornecer potências mais elevadas com maior eficiência e qualidade do feixe. O segundo, por outro lado ganhou espaço ao se tornarem mais fáceis de incorporar robotização, além do surgimento de modelos de maior potência. Mais recentemente os de fibra vem conquistando o mercado por uma série de razões.⁴⁸ O laser de fibra é um laser em que o meio ativo é uma fibra óptica dopada com elementos terras-raras. Ele representa uma nova geração de lasers de potência para processamento de materiais que vem ganhando bastante espaço nos ambientes industriais. As vantagens desse tipo de laser em relação a outros incluem:

- Tamanho compacto (existe no mercado uma infinidade de modelos adaptáveis aos mais diversos ambientes de chão de fábrica);
- Confiabilidade (possuem maior vida útil e baixo custo de manutenção);
- Alta qualidade óptica (feixe estável que permite boa precisão na distribuição térmica de energia do caminho óptico). A performance nesse quesito chega a 4 vezes comparado com lasers Nd:YAG, por exemplo;
- Apresenta spot ou foco com dimensões reduzidas (10 - 100nm), que o torna ideal para trabalhos precisos em aplicações de deposição de materiais.³²

2.2.1.2 Conjunto Alimentador e Injetor de Pó

A garantia de bons resultados aplicando o processo de *Laser Cladding* depende de diversos fatores e um deles é a questão da alimentação do material que será depositado. A alimentação, nesse caso, significa injetar o material na forma de fio ou pó. Uma vez que o uso de fios limita a variedade de materiais que podem ser utilizados, a injeção de pó é o método preferido.⁵³ O Alimentador de pó pode ser considerado um dos itens mais importantes em termos dos equipamentos que compõem um sistema de deposição DML. Há muitos detalhes

envolvidos em torno do projeto dessa parte do sistema em razão de determinados fatores, listados abaixo, que tornam difícil o estabelecimento de um design único que contemple todas as aplicações desejadas:²

- Existência de diferentes tipos de pós disponíveis que variam em termos de tamanho e forma;
- Propriedades de fluidez e coesão do pó utilizado;
- O “fator de vazio” que é a taxa de quantidade de ar preenchendo os espaços vazios entre as partículas do pó.

A seleção de um sistema alimentador de pó adequado é um fator vital para o processo de revestimento a laser por *Laser Cladding* ser bem-sucedido. O sistema deve fornecer um fluxo de pó de modo contínuo e uniforme com alta precisão a uma taxa de alimentação desejada, ou seja, deve haver certo controle dessa taxa em tempo real a fim de evitar pulsações e aglomerações no fluxo do pó durante o processo. Assim, vários sistemas foram pesquisados e desenvolvidos com vistas a realizar tais condições. Em geral, baseado no princípio de operação, os alimentadores de pó se enquadram em quatro categorias:

- **Baseado em gravidade** - Através de um mecanismo eletrônico de pesagem baseado em células de carga, o pó flui do container até o orifício. Ao reduzir ou aumentar a área do orifício, a quantidade de pó entregue ao bico injetor diminui ou aumenta (Figura 2.6 - (a)). A fim de aumentar a capacidade de controle de alimentadores de pó à base de gravidade, diferentes dispositivos como uma roda de medição podem ser integrados no alimentador de pó. Além disso, um gás pode ser utilizado para fornecer pressão ao sistema de escoamento e com isto aumentar a estabilidade do fluxo de pó;
- **Roda mecânica** - Possui um rotor ou fuso que transporta as partículas de pó da área de armazenamento (Figura 2.6 - (b)). Funcionam com diferencial zero ou baixa pressão entre a saída e a entrada;
- **Alimentador por fluido** - Opera com base no princípio da dinâmica dos fluidos, eliminando qualquer movimento de partes mecânicas para transportar o pó. O sistema fornece uma alimentação contínua e não pulsante de pó, garantindo assim o melhor controle do processo e qualidade do revestimento. Outro benefício é a manutenção reduzida e o custo das peças de reposição. O sistema é concebido de modo a que uma quantidade predeterminada de gás seja fornecida ao container contendo pó. O

container é construído de modo que o gás é passado através de um filtro localizado na parte inferior da unidade, onde é difundido através do pó, fazendo com que o pó se junte ao gás tornando-se fluidizado. Um tubo de captação de pó está posicionado acima da entrada permitindo que a mistura fluidizada seja canalizada por tubos de captação através de uma série de aberturas controladas para uma área onde é arrastada pelo gás transportador para a mangueira de alimentação do bocal de injeção (Figura 2.6 - (c));

- **Baseado em vibração** - Consiste em uma bandeja de fundo raso (Figura 2.6 - (d)). À medida que o pó flui da saída do container para a bandeja, um sistema externo imprime uma vibração à bandeja, permitindo a saída do pó. Os níveis de vibração determinam a taxa de alimentação do pó no processo.

Figura 2.6 - Esquema de alimentadores de pó. (a) Sistema baseado na força da gravidade; (b) Rosca mecânica transportadora; (c) Alimentação por sistema de fluido; (d) Baseado em sistema de vibração.

Fonte: Adaptada de TOYSERKANI.²

Os alimentadores de pó fornecem, então, o material ao bocal responsável por injetá-lo no ponto de fusão da área de trabalho. Nos processos de DML por injeção de pó, dois modelos têm sido mais utilizados de acordo a literatura estudada: bocal de injeção lateral e bocal de injeção coaxial sendo este último possível em duas configurações distintas (modo discreto e modo contínuo).

O primeiro deles, o modelo Lateral, configuração descrita por Weisheit *et al.*,⁵³ o bico de injeção é posicionado lateralmente ao feixe do laser. A posição é determinada pelo ângulo entre o bocal e a peça de trabalho (α) e a distância entre a ponta do bico e a peça de trabalho como mostrado na Figura 2.7. Como o fluxo de pó diverge ao sair do bico, a distância (L) deve ser tão pequena quanto possível para uma boa eficiência do processo (quantidade depositada por quantidade injetada do pó). Outro parâmetro que determina a eficiência é a direção da injeção. Quando a direção do fluxo das partículas é a mesma que a direção de movimento da peça de trabalho ou a situação oposta (direção contrária), maior a eficiência do processo. Nestes dois casos citados, as quantidades de pó injetados diretamente na massa fundida são diferentes. Por este motivo, a injeção de pó lateral não é adequada para aplicações de fabricação aditiva em 3D. Geralmente, devido à localização do bocal próximo à área fundida e às reflexões do raio laser, o bico injetor deve ser refrigerado de alguma forma.

Figura 2.7 - Esquema do modelo de injeção de pó lateral.
Fonte: Adaptada de WEISHEIT *et al.*⁵³

Com relação ao segundo modelo de injeção, o coaxial, seu advento teve um grande impacto na tecnologia de *Laser Cladding*. Uma característica importante que este modelo agregou foi a independência em relação à direção de deposição. Com isso, uma melhor eficiência em termos de utilização do pó pode ser obtida por este tipo de bocal, além de permitir a construção de revestimentos com dimensões precisas.⁵⁴

Como já mencionado anteriormente, o modelo de bocal coaxial possui duas classificações: coaxial discreto e coaxial contínuo. O injetor coaxial por injeção descontínua possui vários canais individuais de fluxo para o pó que são distribuídas em torno do raio laser (no mínimo três), formando assim um foco de fluxo de pó. A Figura 2.8 mostra um bocal com três fluxos de pó. O diâmetro do foco formado pela junção dos fluxos de pó depende do ângulo entre os canais individuais de pó, do diâmetro dos orifícios dos bicos, da distância entre a ponta do bico e foco do fluxo de pó, da taxa de alimentação do pó e o tamanho de partícula. A principal vantagem do bico de três vias ou mais em relação ao tipo lateral é o potencial para revestimentos 3D, incluindo a possibilidade de inclinar o bocal durante o processo.⁵³

Figura 2.8 - Bocal de injeção de pó coaxial discreto (três vias).
Fonte: FRAUNHOFER.⁵⁵

Por fim, no último modelo de bocal coaxial, o contínuo (Figura 2.9), o fluxo de pó é distribuído de forma homogênea em torno do raio laser. Este injetor apresenta um design mais complexo bem como sua instalação, pois o bico deve estar perfeitamente alinhado com o raio

laser. Trata-se de uma solução mais cara, porque o bocal é baseado em duas partes cônicas complexas montadas coaxialmente: o bico próximo à zona de deposição que comumente é fabricado em cobre (material de alta condutividade térmica) e as peças internas com geometrias complexas feitas em aço inoxidável (fácil usinagem em relação ao cobre). Embora, de mais alto custo, muitos sistemas de revestimentos a laser utilizam esse tipo de bocal porque o foco de concentração do fluxo de pó nesta configuração é maior em relação aos bocais discretos, significando que a maior parte do pó injetado é direcionada para o ponto de fusão, ou seja, tem-se uma maior eficiência precisão.⁵⁴ Essa característica permite ao bocal coaxial contínuo trabalhar peças que exigem trilhas pequenas ou pequenas partes, por exemplo.⁵³

Como destaca Lamikiz *et al.*,⁵⁴ embora haja uma grande variedade de patentes de sistemas injetores para *Laser Cladding*, todos os projetos são baseados em requisitos semelhantes e em concepções baseadas nos modelos acima descritos. E que apesar do desenvolvimento já conquistado e consolidado, muitos avanços ainda são esperados sobre esse importante item de um sistema DML.

Figura 2.9 - Bocal de injeção de pó coaxial contínuo.
Fonte: FRAUNHOFER.⁵⁵

2.2.1.3 Dispositivo de Posicionamento

O processo de revestimento a laser baseado em DML pode ser usado em uma variedade de aplicações tais como a prototipagem rápida, revestimentos e reparação de

superfícies ou partes. Para todas essas aplicações, um modelo estrutural de movimentação específico e adequado é exigido para a realização da tarefa a contento.² Além disso, as crescentes oportunidades da fabricação aditiva surgem explorando novos conceitos de projeto que não foram considerados no passado devido às limitações dos processos de fabricação mais tradicionais.⁵⁶ Dentro deste contexto, a automação dos processos de *Laser Cladding* vem ganhando espaço. Como argumenta Torres,⁵⁷ com a automação do processo é possível garantir a qualidade dos revestimentos a laser por permitir um controle mais automático das inúmeras variáveis do sistema como um todo.

A maioria dos sistemas de DML utilizam Manufatura Assistida por Computador (CAM) baseada em algoritmos de planejamento de trajetória para identificar os caminhos necessários para o processo de fabricação ou revestimento da parte desejada. Os dispositivos de posicionamento contemplam, neste caso, espaço de trabalho suficiente, manobrabilidade para os percursos necessários e velocidades apropriadas.

O dispositivo de posicionamento pode ser desde um sistema de coordenadas XYZ, exemplo visualizado na Figura 2.10, até um braço robótico manipulador de múltiplos graus de liberdade, tal qual representado pela Figura 2.11. Em ambos os casos, os parâmetros de restrições da dinâmica do sistema de movimentação devem ser cuidadosamente considerados para garantir velocidades e acelerações desejadas em diferentes pontos de trajetória. No caso de um robô, por exemplo, a singularidade das articulações (singularidade acontece caso uma ou mais articulações não representam mais variáveis de controle independentes, causando uma limitação no espaço de trabalho do robô) é uma importante restrição a ser considerada. A fabricação de uma forma complexa usando revestimento a laser por um robô como o dispositivo de posicionamento, depende fortemente deste parâmetro.

Figura 2.10 - Sistema de *Laser Cladding* dotado com controle de posicionamento XYZ.
Fonte: Adaptada de FRAUNHOFER.⁵⁵

Figura 2.11 - Sistema de *Laser Cladding* baseado em braço robótico dotado com seis eixos de movimentação.
Fonte: WANG *et al.*⁵⁸

Em geral, o número de graus de liberdade desempenha um papel importante nos dispositivos de posicionamento usado em sistemas DML. Com relação à velocidade, de acordo com a literatura, para o processo de revestimento a laser por DML o parâmetro varia de 1 mm/s a 20mm/s com base na potência do laser e na taxa de alimentação de pó disponível. No caso da fabricação aditiva de peças, as trajetórias são calculadas por um software CAD/CAM que fornece uma sequência de pontos discretos, representando os trajetos desejados, ao hardware controlador de movimentos do sistema.²

Há ainda sistemas híbridos integrados de manufaturas que integram um centro de usinagem (fabricação subtrativa) acrescido do processo de *Laser Cladding* (fabricação aditiva). Tal alternativa permite alta eficiência pois elimina vários processos fabris agregando valor aos produtos produzidos.¹⁷

2.2.1.4 Controle e Sensoriamento

De acordo com a literatura na área, um dos aspectos cruciais abrangendo a tecnologia de revestimentos de materiais a laser onde o *Laser Cladding* está inserido, é o fator qualidade.^{2,4,22,31-33,40-45} Uma das maiores vantagens da utilização do laser, destacada pelas citações, é justamente este ponto. Entretanto, tal método apresenta relativa complexidade por envolver uma série de parâmetros intrínsecos e extrínsecos ao processo, fator que tem conduzido a muitas pesquisas focadas no estudo e compreensão dos fenômenos que o permeiam. Desses estudos decorreram que, de modo geral, a obtenção de resultados satisfatórios depende de uma grande variedade de fatores envolvidos:^{2,18,27,46}

- **Propriedades do Laser** - Tipo do laser, potência, dimensões do spot, intensidade do spot;
- **Características do Substrato** - Tipo do material, qualidade da superfície, forma;
- **Atributos do Sistema de Injeção** - Taxa de aspersão, ângulo de injeção, tipo do bocal, gás utilizado;
- **Perfil do Pó** - Composição, tamanho e forma da partícula;
- **Dinâmica do Processo** - Velocidade de varredura, passo, quantidade de camadas, controle do ponto focal.

Apesar de vantajosa, a utilização da DML pela indústria é ainda limitada, em grande parte, justamente pelos fatores citados acima. Portanto, atuar no sentido de minimizar tais

aspectos mediante um controle mais acurado mostra-se muito importante. Muitas pesquisas nos últimos anos têm se debruçado sobre esta questão, conforme sugerem, praticamente, todas as referências bibliográficas estudadas neste trabalho. Neste sentido, existem basicamente dois tipos de controle relativo à DML: controle de malha aberta e controle de malha fechada. O primeiro, utilizado na maioria das aplicações industriais atualmente, é relativamente simples: um conjunto de parâmetros é previamente definido e o sistema guiar-se-á por ele. O segundo, por outro lado é bem mais complexo e inovador: utiliza um mecanismo de sensoramento que monitora a saída do sistema (a superfície e/ou camada de depósito) e realimenta a entrada compensando, automaticamente, eventuais discrepâncias, via ajustes nos parâmetros.^{2,40,46-47} Esta segunda opção de controle para o sistema de deposição é considerada o estado da arte no âmbito da DML.^{2,20,25-27,40,42-44,46-47,49-52} Com ela pode-se revestir superfícies de uma maneira mais uniforme e otimizada.^{2,46-47}

Os sistemas de deposição mais comuns, geralmente, contemplam controle de parâmetros pré-definidos, não realizando ajustes automáticos no decorrer do processo (malha aberta). A abordagem mais adotada neste caso é o controle de determinados parâmetros, tais como a potência do laser, distância focal, velocidade de deposição e taxa de injeção de pó, de forma empírica, isto é, ajustes de modo a obter os melhores resultados em uma dada aplicação pelo método de tentativa e erro. Uma vez realizado esse procedimento, o sistema operará rigidamente sob estes valores pré-ajustados. A desvantagem desta concepção de projeto, esquematizada na Figura 2.12, é sua inerente incapacidade de responder a quaisquer variações no funcionamento dos equipamentos e elementos constituintes do sistema no decurso do processo de revestimento impactando no seu resultado final.²

Figura 2.12 - Esquema de um sistema de DML por injeção de pó cujo controle é em malha aberta.

Fonte: Adaptada de TOYSERKANI.²

Por esta razão, a abordagem mais moderna e inovadora de controle em malha fechada, esquematizado na Figura 2.13, tem sido estudada como alternativa à malha aberta, como destacado por vários trabalhos.^{2,25-27,46} Neste método, o processo é monitorado em tempo real sendo que certos parâmetros de entrada do sistema são ajustados de modo autônomo visando compensar qualquer perturbação ou alteração ocorrida. Logo, grandezas mensuráveis como o perfil da superfície e as dimensões e temperatura dos pontos e/ou trilhas depositados, por exemplo, podem ser utilizadas para guiar o sistema no sentido de otimizar o processo e garantir a qualidade do revestimento. A Figura 2.14 apresenta um diagrama de blocos de um sistema de controle em malha fechada com todos os parâmetros envolvidos inclusive os de malha aberta.

Figura 2.13 - Esquema de um sistema de DML por injeção de pó cujo controle é em malha fechada.

Fonte: Adaptada de TOYSERKANI.²

Figura 2.14 - Diagrama de blocos de um sistema de controle completo de DML discriminando a parte de malha aberta e a de malha fechada.

Fonte: Adaptada de TOYSERKANI.²

Do diagrama anterior nota-se o papel essencial que realimentação realiza em estabilizar o sistema, concorrendo para a garantia da qualidade das camadas depositadas. De

fato, conforme demonstrado por Toyserkani,²⁷ que investigaram o desempenho de ambos os tipos de controle na deposição de uma série de camadas sobrepostas, o processo realizado em malha fechada produziu um resultado final significativamente melhor que o apresentado em malha aberta conforme se observa na Figura 2.15. O artigo ressalta que os parâmetros iniciais aplicados a ambos os experimentos foram iguais, o que demonstra a clara influência de distúrbios no processo quando não tratados adequadamente.

Figura 2.15 - Comparação entre dois processos de construção de camadas sucessivas por DML. Imagem superior: controle por malha aberta. Imagem Inferior: controle por malha fechada.

Fonte: TOYSERKANI.²⁷

De um modo geral, O desenvolvimento de um controle de malha fechada para um sistema de *Laser Cladding* envolve a seleção de um parâmetro de entrada que será controlado (a potência do laser, por exemplo), a medição de alguma propriedade do revestimento sendo efetuado (por exemplo, a dimensão do ponto em fusão no substrato, descrito na Figura 2.16) que entra como o sinal de realimentação, e finalmente um controlador (hardware e software) que mede a diferença entre os dois sinais e reajusta o parâmetro de entrada restabelecendo o equilíbrio. Pelo fato de existir uma porção de parâmetros que podem ser usados como sinais de realimentação para o controle em malha fechada de um sistema de DML, várias estratégias podem ser concebidas para realizá-lo. A literatura relata muitas abordagens que foram alvos de estudos sobre esse assunto.^{2,25-27,40,42-44}

Figura 2.16 - Seção transversal de uma camada depositada sobre um substrato. W_c : largura; H_c : altura; A_c : área depositada; A_b : área diluída ou fundida.

Fonte: Adaptada de HOFMAN.²⁵

Os métodos de monitoramento baseiam-se na utilização de fenômenos físicos que ocorrem devido a interações do laser com o material. O princípio de medição pode ser acústico, óptico, elétrico ou térmico, os quais podem ser combinados para melhorar a performance do sistema de leitura. Na prática, os dois parâmetros mais utilizados, de acordo com as pesquisas, para o sensoriamento são a temperatura e as dimensões da camada depositada cujas informações podem ser capturadas por diversas formas: fotodiodos, espectrômetros, pirômetros ou câmeras diversas (CCD^{*}, CMOS[†], IR[‡]).⁴⁴

Uma das estratégias mais bem-sucedidas de controle em malha fechada para DML foi desenvolvida por Toyserkani,^{2,27} esquematizada pela Figura 2.17, em que uma câmera CCD foi usada para controlar a altura da deposição do metal em pó em tempo real. As imagens capturadas eram enviadas para um controlador Proporcional-Integral-Derivativo (PID)[§] que ajustava o nível de energia do pulso do laser de modo a manter a altura da camada no patamar desejado. Bi *et al*,⁴² por sua vez, empregaram vários sensores infravermelhos, além de termômetros e câmera, para monitorar o processo de deposição. Foi implementado um controle baseado na leitura da temperatura por fotodiodos cujos sinais eram mantidos constantes pelo ajuste na potência do laser. Com isso, obtiveram bons resultados em termos da qualidade das camadas depositadas.

* Do inglês, *Charge-coupled Device*.

† Do inglês, *Complementary Metal-oxide Semiconductor*.

‡ Do inglês, *Infrared Radiation*.

§ Do inglês, *Proportional-integral-derivative Controller*.

Figura 2.17 - Sistema de DML empregando controle em malha fechada. Foi utilizado uma câmera como elemento de sensoriamento.

Fonte: Adaptada de TOYSERKANI.^{2,27}

Outras abordagens mais modernas incluem, por exemplo, utilizar a análise de espectro do plasma emitido pelo laser durante sua interação com a superfície do material para monitorar o foco, obtendo, por exemplo, informações como o seu posicionamento e intensidade.^{51,52} Há, ainda, técnicas explorando modelos computacionais,^{30,40} escaneamento a laser,⁴³ visão computacional,²⁸ inteligência artificial⁶¹⁻⁶⁴ e até mesmo sistemas híbridos que fazem uso de vários desses métodos elencados anteriormente.²⁵⁻²⁶

2.2.2 Materiais e Insumos

O *Laser Cladding* permite a fusão de materiais ou ligas metálicas nas superfícies de interesse de dois modos distintos: inserção do material sob a forma de fio/ bastão e a aspersão do material sob a forma de partículas (pó). Entretanto, de acordo com trabalhos de pesquisa, empregar metais na forma de pó produz melhores resultados em relação à qualidade dos depósitos formados e reprodutibilidade do processo.^{2,18,22-25,37}

Uma das principais vantagens de utilização de ligas em pó é que elas podem ser misturadas e escolhidas de acordo com as considerações das propriedades mecânicas desejadas e custos envolvidos.²⁴ Uma grande variedade de pós metálicos pode ser utilizada no processo de deposição com a possibilidade de formar camadas com espessuras na faixa entre 0.1 e 2mm.²⁷ As características e a qualidade do pó podem afetar fortemente o desempenho do processo.^{35,38} Pós metálicos usados em manufatura aditiva possuem formas aproximadamente esféricas (Figura 2.18) e um tamanho e distribuição de partícula que se destinam a facilitar uma melhor densidade de empacotamento, de modo que a parte recuperada tenha boas propriedades mecânicas e fique totalmente densa.

Figura 2.18 - Morfologia de partículas de pó (liga de níquel) utilizadas em processos de *Laser Cladding*.
Fonte: Adaptada de WANG *et al.*⁵⁹

Nas aplicações de *Laser Cladding* as partículas geralmente possuem diâmetro na faixa de 20 a 200μm.⁵³ Outras características incluem morfologia, densidade, composição química, fluxo e propriedades térmicas que em menor ou maior grau influenciam o processo.^{36,39} A escolha correta do pó a ser utilizado depende de uma série de fatores a considerar. Por exemplo, a composição química e porosidade determinam a abrasão e resistência ao calor, impacto ou corrosão. O tamanho das partículas pode influenciar o acabamento do depósito. Além disso, há pós específicos para determinados equipamentos.⁶⁰ O diagrama da Figura 2.19

apresenta um exemplo de guia, proveniente de um grande fabricante, para escolha do pó baseado nas características de resistência desejadas.

Figura 2.19 - Diagrama de Resistência à abrasão versus Resistência à temperatura versus Resistência ao Impacto para algumas ligas mais utilizadas em processos de *Laser Cladding*.

Fonte: Adaptada de HÖGANÄS.⁶⁰

2.2.3 Aplicações

A crescente demanda pela utilização do laser no processamento de materiais pode ser atribuída, entre outros fatores, às várias vantagens únicas da tecnologia a laser, nomeadamente: alta produtividade, automação de processos, processamento sem contato, eliminação de acabamentos (pré ou pós-processos), melhoria da qualidade do produto como resultado do processo, mínimo de desperdício dos insumos utilizados e a garantia de uma menor zona termicamente afetada do material em questão.

Corroborando com o exposto acima, uma das aplicações mais difundidas do *Laser Cladding* é sua utilização no tratamento e recuperação de superfícies metálicas em geral. O metal em forma de pó é pulverizado em direção ao foco de um feixe de raio laser incidente sobre a superfície do substrato sob tratamento de forma simultânea. Como resultado, ocorre a

fusão das partículas do material com o substrato criando uma camada solidamente aderente que praticamente a renova ou modifica de acordo com as características requeridas.

Tratamentos de superfícies metálicas constituem uma etapa ou processo de grande interesse para diversos ramos da indústria com o intuito de prevenir desgastes ou reparar superfícies danificadas, principalmente de componentes mecânicos de alto valor agregado, geralmente designados para operarem em condições extremas de trabalho e/ou atenderem requisitos de segurança imprescindíveis. Métodos tradicionais para realizar tais procedimentos normalmente são custosos e possuem desvantagens significativas. A deposição de metais a laser, por outro lado, é uma tecnologia de processo inovador que possibilita, com precisão e qualidade superior, a adição de metais às superfícies de interesse garantindo um método de menor custo operacional e especializado de revestimento e restauração que culmina no prolongamento da vida útil desses componentes.

Muitos componentes industriais usados em embarcações, motores de aviação, perfuratrizes, geradores de energia, veículos comerciais, ferramentarias e moldes são normalmente submetidos a condições ambientais ou operacionais que potencializam o processo de desgaste. Substituí-los, geralmente, não é a melhor opção por conta do alto custo. Assim, tentar recuperá-los ou prolongar a vida útil torna-se evidentemente vantajoso. Apesar dos vários processos disponíveis que efetivam tal alternativa de reaproveitamento e/ou melhoramento de tais itens de interesse, a DML vem ganhando espaço em virtude de uma série de vantagens em relação a métodos convencionais como a aspersão térmica e o arco elétrico, por exemplo:^{23,25,31-32}

- Menor a área do substrato termicamente afetada o que leva à menor distorção da superfície trabalhada;
- Baixa perda de material base do substrato devido à menor energia térmica utilizada;
- Qualidade superior do depósito constituído sobre a superfície, resultado do rápido processo fusão / solidificação que ocorre localmente em uma pequena área;
- Maior o grau de aderência dos materiais ao substrato permitindo a formação de estruturas mais refinadas e homogêneas;
- Processos menos poluentes e facilmente adaptados à automatização.

A DML, com o intuito de revestir, reparar e/ou modificar a superfície de artefatos mecânicos, como demonstrado pela Figura 2.20, vem se consolidando como uma tecnologia bastante flexível que permite sua utilização em muitos segmentos:

- Deposição de camadas especiais de determinados materiais metálicos ou mesmo cerâmicos destinados a aumentar a resistência de superfícies (ferramentas, moldes, eixos, mancais etc.) ao desgaste, calor, corrosão/oxidação;^{23,31}
- Reparação de componentes usados na indústria aeroespacial, mecânica de precisão e equipamentos médicos os quais necessitam de trabalhos de soldagem delicados e precisos que não danifiquem as superfícies tratadas;³²
- Reconstrução parcial ou total de partes danificadas ou seccionadas pela ação do tempo em estruturas diversas;^{4,33}
- Reconfiguração espacial da superfície de objetos para atender demandas específicas em termos de reaproveitamento ou adequações de projeto,^{31-32,34} entre outros.

Figura 2.20 - Restauração de eixo mecânico utilizando Laser Cladding.
Fonte: Adaptada de TORIMS.³¹

3 VISÃO COMPUTACIONAL

Com o advento da computação, um amplo campo de pesquisas se abriu com o intuito de se produzir ferramentas úteis ao desenvolvimento da sociedade. Dentre estas, o anseio em desenvolver formas de máquinas poderem mimetizar o comportamento humano tem-se mantido obstinadamente em evidência.⁶⁵ Sistemas munidos com as capacidades de “ver” e “pensar” tornaram-se objetos de inúmeros trabalhos desde então. De fato, máquinas dotadas com o sentido da visão, por exemplo, seriam capazes de reconhecer rostos, sinais, gestos, objetos e paisagens, tornando-as especialmente interessantes em um rol de aplicações.⁶⁶

3.1 DEFINIÇÃO

Remetendo inicialmente ao termo processamento digital de imagens, desenvolvido nos anos 60, o foco dos primeiros trabalhos científicos na área residia na tarefa de manipular as imagens captadas pela câmera através de algoritmos, resultando em novas imagens. Mais tarde, a tendência passou a ser a análise de imagens, ocasião em que o termo visão computacional* toma espaço,⁶⁷ passando a caracterizar o elo entre o processamento de imagens e a interpretação do conteúdo visual das mesmas.⁶⁸ Neste sentido, a visão computacional pode ser definida, então, como a propriedade de um sistema em observar visualmente um determinado ambiente, analisando, inferindo e extraíndo informações relevantes de uma imagem ou vídeo (sequência de imagens).⁶⁹

Desde seus primórdios, a visão computacional, vislumbrada em sua plenitude de solucionar satisfatoriamente todos os problemas abordados, tem esbarrado nas dificuldades intrínsecas do processo em si. O aspecto mais desafiador envolvendo técnicas de reconhecimento visual é o fato de existirem múltiplos fatores que afetam ou se relacionam a uma imagem em particular, tornando excepcionalmente complexo a modelagem de todos esses elementos.⁷⁰ Ademais, como sustentam Bradski⁷¹ e Huang,⁷² comparar a visão computacional com a capacidade inata do cérebro humano no que tange ao processo de visão

* Outros sinônimos são encontrados na literatura tais como visão artificial, visão de máquina, visão robótica, visão de computador, entre outros.

e decorrente tomada de decisão é uma meta ainda impraticável. Contudo, o aumento do poder de processamento dos computadores e o grande volume de dados disponíveis, combinados com o rápido desenvolvimento da capacidade da câmera digital e sua respectiva redução de custo, resultou nos últimos anos em notáveis avanços na área.

A visão computacional abrange uma enorme esfera de estudos (Figura 3.1), cobrindo áreas desde as clássicas as mais recentes, como, por exemplo:⁷³

- **Psicologia** - A compreensão dos limites e capacidades visuais dos seres humanos em realizar tarefas permite obter importantes insights acerca do projeto de sistemas de visão computacional;
- **Física** - A óptica desempenha um papel fundamental em tais sistemas, uma vez que estes lidam com a luz e sua interação com as superfícies;
- **Estatística** - A utilização de modelos estatísticos, desenvolvidos para o cenário experimental, permite avaliar a probabilidade de cada resultado e escolher o que seja mais consistente com as observações;
- **Robótica** - O emprego da visão computacional em sistemas de navegação móvel é notório;
- **Neurociência** - O estudo do olho humano, sistema nervoso central e cérebro fornecem pistas valiosas para o desenvolvimento da área.

Figura 3.1 - A visão computacional como intersecção de múltiplas áreas científicas.

Fonte: Adaptada de KRISHNA.⁷⁴

3.2 PROCESSOS ENVOLVIDOS

De acordo com a literatura, os processos envolvendo um sistema de visão computacional se desenvolvem em etapas, tal como ilustrado na Figura 3.2. Inicia-se pela aquisição da imagem que é submetida, na sequência, à passos de pré-processamento para, então direcionar-se às tarefas de visão propriamente dita. Para Gonzales,⁷⁵ são necessários três estágios principais para a completude do processo, que consiste basicamente em receber uma imagem como entrada para o sistema e fornecer uma interpretação desta mesma imagem como saída:

- **Estágio de baixo-nível** - Considerada uma etapa de pré-processamento, esta baseia-se em operações primitivas sobre a imagem captada, com o objetivo de suprimir ruídos e melhorá-la em determinados aspectos, por meio de processos de filtragem, ajustes de contraste, entre outros;
- **Estágio de nível-médio** - Fase que realiza o processo de segmentar a imagem em partes distintas caracteristicamente ou de classificar tais regiões através de detectores de certos atributos geométricos (bordas, cantos, pontos, etc.);
- **Estágio de alto-nível** - Última parte do processo que consiste em reconhecer os objetos contidos na imagem ou compreender uma cena tornando o sistema apto a analisar e tomar as ações desejadas.

Figura 3.2 - Etapas de um sistema de visão computacional.
Fonte: Elaborada pelo autor.

Nas próximas subseções, os aspectos mais relevantes dessas etapas são brevemente delineados.

3.2.1 Aquisição de Imagem

Imagens são o cerne da visão computacional, assim, se não forem satisfatoriamente captadas, os resultados podem apresentar-se aquém do esperado.⁷⁶ Fatores presentes em um sistema de aquisição como câmeras, lentes, foco, iluminação, profundidade de campo, sensibilidade do sensor, tempo de exposição e outros conceitos da ótica e da fotografia devem evidentemente ser considerados.⁷³ Convenientemente, os avanços tecnológicos nessa área têm sido frutíferos, como salientado por Marshall⁷⁷ ao citar, como exemplo, o advento das câmeras digitais dotadas de sensores CCD.

A luz proveniente de uma cena atravessa um conjunto de lentes e atinge, durante um determinado tempo de exposição ou abertura, um conjunto de sensores de imagem embarcados e dispostos em forma matricial na câmera, sensibilizando-os, de sorte que pequenos sinais elétricos são gerados. Em relação a estes sensores, há dois tipos principais em voga atualmente: CCD e CMOS. O primeiro deles utiliza uma matriz de minúsculos capacitores acoplados que são carregados proporcionalmente à intensidade da luz interceptada durante o tempo de exposição, sendo suas cargas transferidas, após este intervalo, por um circuito de controle, a amplificadores e então, a conversores analógico-digitais. O segundo, por sua vez, emprega fotodetectores juntamente com transístores que, localmente, já realizam a amplificação dos sinais, digitais por natureza, neste caso, devido à ação comutadora do semicondutor. Com menor custo e qualidade crescentes, as câmeras baseadas em CMOS vem superando as tradicionais CCD em termos de popularização.⁷⁰

O resultado final desse processo de amostragem e quantização dos sinais captados pelos sensores é precisamente a obtenção de uma imagem digital, que é caracterizada por uma matriz bidimensional de números binários e finitos, cujos valores representam apropriadamente a cor de cada um de seus pixels. Imagens em tons de cinza, por exemplo, são representadas digitalmente dentro do intervalo de números naturais (0 - 255), sendo, por conveniência, o valor zero atribuído à cor preta e o 255 à cor branca, e assim, 256 níveis de cinza diferentes são possíveis. Imagens coloridas, por outro lado, podem ser assinaladas por

três matrizes, considerando um sistema de cores RGB*. Neste caso, cada matriz especifica a quantidade de vermelho, verde e azul que compõem a imagem. E, similarmente às imagens em cinzas, adota-se, por convenção, atribuir o valor zero à ausência de intensidade e o 255 à máxima intensidade de cor conferida a cada pixel.

3.2.2 Pré-processamento

A imagem captada e transformada no formato digital é submetida, então, a um conjunto de processos destinados a prepará-la adequadamente para as próximas etapas. Com este intuito, variadas técnicas de realce da imagem, baseadas em operações realizáveis no domínio espacial e da frequência, podem ser utilizadas. São processos, geralmente, orientados às particularidades das aplicações em questão, mantendo um caráter predominantemente subjetivo, isto é, propensos ao olhar particular do observador.⁷⁵

Aplicações efetuadas diretamente sobre os pixels da imagem pertencem ao domínio espacial e podem ser categorizadas em dois grupos: transformações de intensidade e filtragem espacial. O primeiro, que opera individualmente com os pixels da imagem, proporciona algumas técnicas de realce da imagem, tais como a obtenção de imagens negativas, o alargamento de contraste e a manipulação do respectivo histograma (Figura 3.3). Este último, em particular, é muito utilizado para melhorar o contraste de uma imagem via processo de equalização. O histograma de uma imagem pode ser descrito como uma função discreta que estima a frequência com que os pixels com um dado nível de cinza aparecem na imagem, podendo ser representada graficamente. O segundo grupo, por sua vez, utiliza máscaras, também nomeadas de filtros, *kernels*, *templates* ou janelas, que operam sobre a vizinhança de cada pixel da imagem. São numerosas técnicas de filtragem, amplamente utilizadas na área de processamento de imagens, que propiciam efeitos de suavização, como por exemplo, a redução de ruídos, remoção de pequenos detalhes e a conexão de pequenas discontinuidades, além da técnica de aguçamento que objetiva destacar detalhes finos ou transições de intensidade presentes na imagem (Figura 3.4).^{75,79}

* Do inglês, *Red-Green-Blue* (Vermelho-Verde-Azul).

Figura 3.3 - Exemplos de realce de imagens utilizando técnicas de transformações de intensidade. (a) Esq.: Imagem original; Dir.: Imagem Negativa. (b) Esq.: Imagem original; Dir.: Resultado do alargamento de contraste. (c) Esq.: Imagem escura original; Dir.: Histograma da imagem. (d) Esq.: Imagem original equalizada; Dir.: Histograma equalizado da imagem.

Fonte: GONZALEZ.⁷⁵

Figura 3.4 - Exemplos de aplicação com filtros espaciais. (a) Esq.: Imagem original de microscopia de revestimento metalúrgico; Dir.: Resultado da aplicação de filtro de suavização. (b) Esq.: Imagem original de uma fratura cerâmica; Dir.: Resultado da aplicação de filtro de aguçamento.

Fonte: RUSS.⁷⁹

Com relação ao processamento de imagens no domínio da frequência ou da transformada, como também é conhecido, sua utilidade se faz presente em determinadas aplicações, como por exemplo, situações em que o custo computacional de se trabalhar no domínio do espaço seja maior. Técnicas de realce que operam no domínio da frequência são baseadas nas transformadas de Fourier da imagem. O mecanismo básico do processo consiste em transformar a imagem de entrada, multiplicar o resultado por uma função de transferência

de filtro e aplicar a transformada inversa retornando a imagem modificada.⁷⁸ A Figura 3.5 apresenta um exemplo de suavização a fim de atenuar o efeito de impressão em meio-tom*.

Figura 3.5 - Suavização do efeito de meio-tom em uma imagem estampada utilizando técnica de meio-tom. (a) Imagem original. (b) Espectro de Fourier (aplicação do filtro tipo *top-hat*). (c) Resultado final.
Fonte: RUSS.⁷⁹

Os métodos de correção de defeitos em imagens, implementáveis em ambos os domínios, conforme a adequação, diferem, em certo sentido, das técnicas utilizadas para realçá-las. O processo de corrigir ou restaurar uma imagem degradada é, na maioria das vezes, uma ação objetiva, baseada em um conhecimento prévio do problema deparado. Isto possibilita o desenvolvimento de critérios e estimativas apoiadas em formulações matemáticas para o processo de recuperação das imagens alvo.⁷⁸⁻⁷⁹

Outra abordagem pertinente a esse estágio preparatório para o processo de visão computacional trata da compressão de imagens, que lida com a tarefa de minimizar a quantidade de dados suficientes para a representação de uma imagem digital para fins de armazenamento e transmissão. Com a expansão da internet e tecnologias emergentes, uma forte demanda por conteúdo visual tem-se estabelecido, e com isto, a necessidade contínua de aprimoramentos nessa área.⁷⁸

3.2.3 Segmentação

* Trata-se de um método de impressão de imagens (*halftone* em inglês) que ao variar o tamanho e/ou densidade dos pontos de tinta de uma ou mais cores, permite simular tons contínuos. Fonte: <https://www.britannica.com/technology/halftone-process>

Para facilitar a análise de imagens, bem como o reconhecimento de padrões, em visão computacional, uma essencial e excelente estratégia é segmentá-la em regiões, as quais podem ser independentemente processadas e analisadas de acordo com o objetivo pautado. Considerada como uma das etapas mais críticas no processamento de imagens digitais, tal artifício, denominado como segmentação, consiste em subdividir a imagem pré-processada, produzida pelo estágio precedente, em áreas correspondentes a estruturas ou objetos de interesse. O particionamento de tais regiões é realizado com base em determinadas características como as similaridades ou discontinuidades dos níveis de intensidade e a distribuição das propriedades dos pixels (limiares de intensidade ou cor) presentes na imagem.⁸⁰ Os tipos de segmentação de imagens comumente utilizados na prática podem ser classificados em:^{75,78-80}

- **Deteção de pontos, linhas e bordas** - São métodos baseados na detecção de mudanças abruptas de intensidade em pontos localizados na imagem. Nesse contexto, um ponto detectado se refere a um pixel isolado, cujo valor de nível de cinza seja suficientemente diferente dos respectivos vizinhos, uma borda é uma faixa limítrofe entre duas regiões apresentando níveis de cinza distintos e uma linha é simplesmente um segmento de borda que apresenta espessura de 1 pixel e valores de intensidade extremos inferiormente ou superiormente em relação aos que se encontram em cada lado desta linha. A Figura 3.6 exemplifica o conceito deste método, utilizado como base em vários algoritmos famosos como o filtro de *Canny* e os operadores *Sobel* e de *Laplace*;

Figura 3.6 – Mecanismo para a detecção de pontos, linhas e bordas numa imagem: utiliza-se cálculos de derivada para os níveis de intensidade identificando as transições abruptas. (a) Imagem contendo objetos sólidos, uma linha e um ponto de ruído interno. (b) Perfil de intensidade horizontal na altura central da imagem passando pelo referido ponto.

Fonte: GONZALEZ.⁷⁵

- **Limiarização (*Thresholding*)** - Nesta técnica, apontada como a mais simples, a imagem é segmentada em regiões de acordo com valores limiares de distribuição das propriedades dos pixels que tais áreas apresentam (Figura 3.7). Basicamente, é definida (manual ou automaticamente) uma faixa de valores de nível de cinza ou cores pertencentes à imagem que inclua os objetos ou regiões de interesse (plano objeto), rejeitando os demais valores para o plano de fundo da cena (*background*);

Figura 3.7 - Segmentação baseada em limiarização global ótima utilizando o método de *Otsu* que trabalha com a maximização da variância entre classes. (a) Imagem ruidosa original. (b) Histograma original. (c) Resultado da limiarização. (d) Imagem original submetida à filtragem. (e) Histograma da imagem suavizada. (f) Resultado final.

Fonte: GONZALEZ.⁷⁵

- **Segmentação por regiões** - Trata-se de técnicas de segmentação que rotulam as regiões de forma direta nas imagens por meio de agrupamento ou divisão de pixels adjacentes cujas propriedades (intensidade, cor, textura ou forma) sejam similares;
- **Segmentação baseada em cores** - Processos geralmente considerados híbridos (combinados com outros métodos de segmentação) e alicerçados nos modelos de

espaço de cor (HSI^{*}, RGB, etc.). Utiliza propriedades como vetor, matiz e saturação de cor para a segmentação da imagem;

- **Segmentação por profundidade** - Baseia-se em informações acerca de mudança de movimentos detectados entre dois quadros de imagem, vide comparação pixel a pixel (no caso de as operações serem efetuadas no domínio do espaço) ou transformada de Fourier (quando forem realizadas no domínio da frequência).

Há um sem-número de técnicas de segmentação desenvolvidos e aprimorados ao longo de anos de pesquisa. Optar por uma delas depende, em grande parte, das características específicas da aplicação em si, como relatado por vários autores.⁷⁴⁻⁸⁰ Não raro, muitos métodos são hibridamente utilizados juntamente com outras ferramentas para o refinamento dos resultados. Um bom exemplo de ferramental de apoio são os chamados filtros morfológicos, que possuem a capacidade de alterar uma imagem de forma gradual e detalhista aplicando operadores matemáticos.⁷⁹⁻⁸⁰ Ruídos, pontos discrepantes ou pixels isolados podem ser eliminados por esses poderosos instrumentos. Basicamente, as principais operações morfológicas, demonstradas na Figura 3.8 e resumidamente descritas abaixo, são a erosão, dilatação, abertura e fechamento:

- **Erosão** - Consiste em computar um mínimo local sobre a área de uma determinada máscara especificada em tamanho e forma (elemento estruturante) que age sobre a imagem conforme o escaneamento da mesma. O efeito é suavizar saliências sendo as regiões em branco da imagem isoladas e encolhidas;
- **Dilatação** - Computa, neste caso, um máximo local sobre a área de uma determinada máscara especificada em tamanho e forma, agindo sobre a imagem conforme seu escaneamento. O efeito é suavizar concavidades sendo as regiões em branco da imagem expandidas e juntadas;
- **Abertura** - Utiliza uma combinação de erosão e dilatação nesta sequência. O efeito é a remoção de pequenas regiões em branco da imagem sendo as regiões em branco remanescentes isoladas, mas mantendo o mesmo tamanho;
- **Fechamento** - Utiliza, por sua vez, uma combinação de dilatação e erosão em sequência. O efeito é o ajuntamento das regiões em branco da imagem, mas mantendo o mesmo tamanho.

^{*} Do inglês, *Hue-Saturation-Intensity* (Matiz-Saturação-Intensidade).

Figura 3.8 - Demonstração dos efeitos produzidos pelos operadores morfológicos Erosão, Dilatação, Abertura e Fechamento. Notar que as duas últimas operações são combinações das duas primeiras, sendo a ordem de aplicação determinante para o resultado final.

Fonte: Adaptada de RUSS.⁷⁹

3.2.4 Extração de Atributos

As regiões particionadas da imagem caracterizam-se por aglomerados de pixels segmentados ao longo da fronteira ou interior a esses locais, aos quais devem ser imputados um atributo ou representação e a respectiva descrição das características dos mesmos, visando a próxima etapa do processo de visão. Uma região pode ser representada baseando-se em aspectos como tamanho, forma, localização e propriedades dos pixels (Figura 3.9). Há uma variedade de meios (denotados como descritores) de se descrever caracteristicamente a região em termos de tais atributos. Geralmente, um conjunto de descritores são combinados para formar uma assinatura do objeto a ser extraído da imagem.⁷⁸⁻⁸⁰

O resultado desse processo é a obtenção de dados numéricos apropriados para o processamento computacional subsequente e, ao mesmo tempo, munidas de informações quantitativas relevantes que podem ser utilizadas para fins de diferenciação das classes de objetos envolvidas.^{75,76,78} Como ilustração, atributos como área e direção de determinadas áreas de interesse da imagem podem ser diretamente obtidos via procedimentos simples de

cálculo geométrico centrado na distribuição dos pixels, linha por linha da imagem, sendo o resultado armazenado em uma sequência ou cadeia de caracteres, a qual define a codificação da característica desejada (uma borda, por exemplo).

(a)

(b)

(c)

Figura 3.9 - Métricas utilizadas para caracterização de atributos em imagens. (a) Esq.: Imagens de filme exposto ao raio X, onde a densidade e posição das linhas são utilizadas para mensurar a estrutura cristalina de um dado material. Dir.: Plotagem da média das intensidades dos pixels ao longo da vertical para as imagens superior e inferior e a subtração entre elas, permitindo análise mais acurada. (b) Esq.: Imagem de grãos de arroz. Centro: Cores atribuídas às imagens segmentadas de acordo com o ângulo dos grãos detectados. Dir.: Distribuição dos grãos conforme os respectivos ângulos. Obs.: os grãos da borda não são levados em conta pelo algoritmo. (c) Esq.: Imagem de microscopia eletrônica de uma amostra de liga de aço com os grãos coloridos de acordo com o elemento químico presente. Dir.: Plotagem da frequência de distribuição do número de grãos vizinhos.

Fonte: RUSS.⁷⁹

3.2.5 Reconhecimento e Base de Conhecimento

Com a representação e a descrição dos objetos ou regiões segmentadas em uma imagem, finalmente, em sua última etapa do processo, o sistema de visão computacional pode reconhecer tais elementos, interpretar os resultados e armazená-los em uma base de dados, de forma automática ou com o mínimo de intervenção humana possível. Ao contrário das técnicas e métodos arrolados nas etapas anteriores, pautadas por formulações teóricas relativamente bem definidas, o processo de reconhecimento de uma característica particular em uma imagem traz consigo certos aspectos cognitivos que demandam critérios de alta complexidade, principalmente em cenários ricos em objetos ou padrões, de sorte que os sistemas de reconhecimento, para serem exequíveis, geralmente configuram-se como altamente especializados em termos do trabalho a ser executado.^{70,78}

A base para o reconhecimento de objetos se alicerça na existência de padrões que são definidos como arranjos de características identificados em uma cena, sendo normalmente classificados em estruturais^{*} ou quantitativos[†].⁸¹ Árvores e *strings* são as formas de representação mais comuns para o primeiro caso, enquanto vetores são para o último. Métodos estruturais baseiam-se na análise da forma ou esqueleto[‡] dos padrões observáveis, mantendo um caráter qualitativo. Técnicas quantitativas, por outro lado, se apoiam em funções de decisão teórica ou análise discriminante que se baseiam em cálculos oriundos do campo da estatística multivariada, responsáveis por discriminar e classificar objetos através da comparação das diferenças entre grupos destes entes e a respectiva classificação individual conforme perfis similares.^{70,75}

Um dos exemplos mais simples e pioneiros de método de detecção já implementados, de acordo com Russ⁷⁹ é o reconhecimento de caracteres (OCR)[§] que utiliza um caso restrito da técnica de casamento por correlação, baseada na comparação direta entre os caracteres alvo e uma base de exemplos pré-definidos (Figura 3.10 - (a)). No outro extremo, intensas pesquisas realizadas em um subcampo popular da visão computacional que lida com a extração e interpretação de tipos de dados visuais específicos, a detecção de faces humanas em uma imagem, têm produzido resultados bastante satisfatórios, apesar da complexidade do problema (Figura 3.10 - (b)).⁸⁰

^{*} O termo “sintática” também é encontrado na literatura.

[†] Alguns autores denominam “estatísticos”.

[‡] O esqueleto de uma região é uma representação reduzida da mesma em formato de grafo, obtida por algoritmos de afinamento.

[§] Do inglês, *Optical Character Recognition*.

Nestes dois exemplos de detecção mencionados acima um elo entre eles é a necessidade de uma base de conhecimento prévio que viabiliza o sucesso da aplicação. Na prática, como menciona Gonzalez,⁷⁵ Russ⁷⁹ e Duda,⁸² o escopo de uma estrutura de reconhecimento de padrões engloba, normalmente, um banco de dados baseado em informações acerca da natureza do problema tratado (imagens, listas de atributos, parâmetros, métricas, etc.), que interage com todos os módulos de processamento constituintes do sistema, alimentando dados ou se realimentando dos novos produzidos durante todo o processo de visão. Tal dinâmica leva ao aprimoramento dos algoritmos classificadores utilizados, procedimento este, descrito como “treinamento”. Esta capacidade de sistemas de reconhecimento aprenderem com o próprio processo, aperfeiçoando os resultados, a literatura tipifica como uma forma de “aprendizado de máquina”, assunto tratado no próximo capítulo.

Figura 3.10 - Exemplos de técnicas de reconhecimento de padrões. (a) Método de Correlação: envolve varrer as áreas de interesse da imagem realizando uma comparação pixel a pixel e computando a soma de diferenças ou outra função de comparação. No exemplo ilustrado, a letra “E”, alvo de reconhecimento, é combinada com cada *template* ou padrão armazenado em memória (caracteres “A-E” formados por pixels pretos contrastados com fundo branco) empregando uma função de OU-exclusivo de modo a contar o número de pixels que casam e aqueles que não. De todas as comparações, aquela cujo cálculo da diferença entre o total de pixels casados e os não casados possua maior valor positivo resulta na identificação do caractere. (b) Método de reconhecimento facial *Haar-like*: baseado no algoritmo de Viola-Jones,⁸³ trata-se de utilizar um conjunto de padrões retangulares compostos de pixels claros e escuros em determinadas proporções para investigar objetos padrões em uma imagem por meio de variações de luminosidade em diferentes direções e amplitudes. A face humana possui elementos característicos como os olhos, nariz e boca que podem ser identificados com o retângulo apropriado.

Fonte: Adaptada de RUSS⁷⁹ (a) ; ADDICAN (b).⁸⁰

4 APRENDIZAGEM DE MÁQUINA

A partir dos dados extraídos e interpretados corretamente de uma imagem, modelos podem ser elaborados, permitindo prever padrões os quais podem, então, ser replicados em inúmeras situações de interesse prático. Sistemas comportando-se, assim, é o que se convencionou denominar de aprendizagem de máquina^{*}, uma subárea da inteligência artificial, caracterizada pelo desenvolvimento de um conjunto de técnicas baseadas em algoritmos responsáveis por treinar e aperfeiçoar o sistema, habilitando-o a operar autonomamente em problemas de reconhecimento, predição, ordenamento e classificação de padrões de dados em geral, como vastamente ilustrado pela literatura vigente.

4.1 CONTEXTO

Formalmente, a aprendizagem de máquina envolve o estudo de teorias e tecnologias para modelagem de conjunto de dados orientadas ao treinamento de algoritmos capazes de generalizar soluções.⁸⁴ Pesquisas nessa área se desenvolveram paralelamente ao da visão computacional. Baseadas inicialmente na Teoria de Decisão Bayesiana[†] e no algoritmo K-ésimo vizinhos mais próximos (KNN)[‡], aos poucos, outros métodos vieram à tona com o advento das redes neurais mais sofisticadas, além das máquinas de vetor suporte (SVM)[§], dos algoritmos de *Boosting*^{**} e mais recentemente da proeminente aprendizagem profunda^{††}.⁷⁶ Com os últimos avanços no setor, conquistados a partir da última década, o termo *machine learning* se popularizou e o alçou como um campo de pesquisas de interesse geral dado o fantástico potencial de computadores modificarem ou adaptarem suas ações, seja predizendo ou controlando, em prol de uma melhor acurácia dessas decisões, resultando na proposição de

^{*} Do inglês, *Machine Learning*. A tradução para o português apresenta duas maneiras: “aprendizagem” e “aprendizado” de máquina, sendo que ambas estão corretas, de acordo com a norma culta da língua. Fonte: <https://ciberduvidas.iscte-iul.pt/consultorio/perguntas/aprendizagem-e-aprendizado/21188>

[†] Pautada pela Teoria de Bayes (matemático inglês Thomas Bayes (1701-1761)), a inferência bayesiana realiza uma abordagem estatística para reconhecimento de padrões.

[‡] Do inglês, *K-nearest-neighbor*.

[§] Do inglês, *Support Vector Machine*.

^{**} Família de algoritmos de aprendizado de máquina que converte classificadores fracos em fortes. Fonte: <https://www.datalabserasaexperian.com.br/datalab/boosting-1-arvores-de-decisao-e-gradient-boosting/>

^{††} Do inglês, *Deep Learning*.

respostas minimamente razoáveis a eventos até então inexecutáveis para uma máquina ou mesmo além das capacidades humanas em desempenhá-las.⁸⁵⁻⁸⁶

Pela facilidade em lidar com quantidades de informações, obtendo resultados úteis, o desenvolvimento desses algoritmos tem sido amplamente potencializado pelo infindável volume de dados coletados e armazenados pelos dispositivos e sistemas computacionais e de comunicação ao longo dos anos.⁸⁴⁻⁸⁶ Como reflexo, a aprendizagem de máquina tem coberto um vasto espectro de aplicações,⁸⁷ incluindo, por exemplo, tópicos relativos à visão computacional, como a detecção e reconhecimento automático de padrões em imagens, que é a linha de trabalho desta dissertação.

4.2 TIPOS DE APRENDIZAGEM DE MÁQUINA

A aprendizagem de máquina envolve o conceito de aprendizado que é bastante amplo na prática. No contexto dessa ferramenta, “aprender”, conforme conceitualmente generalizado pela literatura, significa converter experiências adquiridas a partir da entrada de dados do sistema em conhecimentos que resultem em resultados melhores nas tarefas cumpridas pela máquina. Todavia, a vaga ideia de melhorar a saída de um sistema conduz a certas indagações dado os objetivos pretendidos para as ações realizadas.⁸⁷ Questões como saber se os algoritmos estão aprimorando ou não o processo, o quanto e como melhorá-los, e os tipos e níveis de entradas e saídas desejadas, por exemplo, vêm à tona.⁸⁵ Respostas a tais questionamentos levam naturalmente, de acordo com alguns autores,^{82,84-89} ao estabelecimento de uma classificação dos diferentes algoritmos utilizados nos processos de aprendizagem, resumidas abaixo, embora na prática, sobreposições e outras formas intermediárias, híbridas ou mesmo mais complexas sejam previstas pela literatura, sobretudo pelo dinamismo das pesquisas nessa área:

- **Aprendizado supervisionado** - Consiste em utilizar um conjunto de exemplos corretos (respostas desejadas ou dados rotulados) para o treinamento do algoritmo, fazendo com que este construa um modelo que responderá corretamente e de forma generalizada às novas entradas do sistema;
- **Aprendizado não supervisionado** - O algoritmo, neste caso, não recebe nenhum tipo de informações ou respostas para as saídas (conhecimento de como os dados devam

ser classificados), as encontra, efetivamente, por meio da identificação de similaridades entre as entradas e decorrente categorização dos resultados em grupos;

- **Aprendizado semi-supervisionado** - Considerada uma variação da abordagem supervisionada, este mecanismo, fruto recente de pesquisas em aprendizagem de máquina, emprega uma combinação de um pequeno conjunto de dados rotulados com um outro conjunto de dados não rotulados, cujo tamanho é bem superior ao primeiro;
- **Aprendizado transdutivo** - Trata-se de um método de treinamento semi-supervisionado em que o objetivo é prever rótulos apenas para o conjunto de dados não rotulados;
- **Aprendizado indutivo** - Diferente do algoritmo semi-supervisionado do método anterior, considera-se, neste caso, tantos os conjuntos rotulados quanto os não rotulados para inferir o modelo de classificação;
- **Aprendizado por reforço** - Utiliza processos que exploram dinamicamente, por tentativa e erro associado com punições e recompensas, uma sequência de ações via interações com o meio, visando a obtenção de uma sequência correta para se alcançar o objetivo;
- **Aprendizado evolucionário** - Baseado nos conceitos da evolução biológica que relaciona a taxa de sobrevivência e descendência das espécies com a adaptação desses organismos no ambiente em que se encontram, neste tipo de aprendizado o algoritmo utiliza uma forma de pontuação a fim de estabelecer quão ideal é a solução produzida;
- **Aprendizado *on-line* (incremental)** - A aprendizagem ocorre em um cenário envolvendo múltiplas rodadas em que as fases de treinamento e de teste são mescladas, ou seja, o treinamento ocorre conforme os dados são coletados, de forma que o algoritmo aprende com a própria resposta a cada exemplo apresentado;
- **Aprendizado em lotes (*mini-batch learning*)** - diferentemente do esquema *on-line* descrito no tópico anterior, neste paradigma de aprendizagem, todos os dados de treinamento estão disponíveis antes do processo, tendo o algoritmo acesso ilimitado a estes dados, os quais podem se apresentar em grandes quantidades (o acesso é realizado a qualquer instante e de forma particionada ou em lotes);
- **Aprendizado ativo** - Baseia-se em um cenário supervisionado, com poucos exemplos rotulados disponíveis, em que o algoritmo interage com o ambiente podendo operar seletivamente com os dados ou solicitar novos para construir o modelo treinado;

- **Aprendizado passivo** - O modelo treinado é criado a partir das informações fornecidas sem qualquer influência ou interação por parte do algoritmo utilizado.

Dos tipos de aprendizagem listados acima, costuma-se na prática considerar a aprendizagem supervisionada e a não supervisionada como as duas principais categorizações para os algoritmos utilizados como classificadores ou reconhecedores de padrões, sejam eles rotulados ou não, conforme verificado na literatura. Na seção seguinte serão descritos resumidamente dois dos algoritmos de aprendizagem de máquina mais utilizados para este tipo de tarefa e eleitos para o desenvolvimento deste trabalho.

4.3 ALGORITMOS NOTÁVEIS

Ao se cogitar a utilização de aprendizagem de máquina em uma determinada aplicação o primeiro desafio que se depara é a escolha de qual algoritmo trará as melhores soluções. Além disso, como relatado por Domingos,⁹⁰ milhares de algoritmos encontram-se disponíveis atualmente, sendo tal cifra crescente ao longo dos anos. Um aspecto importantíssimo ainda apontado é a capacidade do algoritmo em generalizar além dos exemplos do conjunto de treinamento (que é naturalmente sua meta) evitando problemas de *overfitting**. Face a este cenário o autor propõe, como um norte, a observância de três componentes fundamentais que combinados caracterizam o algoritmo:

- **Representação** - O algoritmo classificador deve ser representado em alguma linguagem formal de modo que o computador possa manipulá-lo da melhor maneira possível. Atenta-se, também, com relação a este aspecto, como representar os dados de entrada;
- **Avaliação** - A distinção entre bons e maus algoritmos se concretiza através da utilização de uma função de avaliação dos mesmos;
- **Otimização** - A escolha da técnica de otimização é fundamental para a eficiência do treinamento, além de ajudar a determinar o classificador adequado nos casos em que este apresente uma função de avaliação com mais de um ponto ótimo.

* Problema que ocorre quando o modelo se adapta muito bem aos dados de entrada de treinamento, mas não generaliza bem para os novos dados.

Dentre tão grande leque de opções, vários algoritmos, entre eles as SVMs, se notabilizaram ao serem empregados na solução de diversas classes de problemas complexos dos quais a classificação de imagens é um bom exemplo.^{88-89,91} Redes neurais artificiais utilizando muitas camadas escondidas (aprendizagem profunda) como as Redes Neurais Convolucionais (CNN)^{*}, vem sendo recentemente aplicadas, com expressivos resultados, na efervescente área de detecção e reconhecimento facial em tempo real, bem como de inúmeros tipos de objetos, em imagens, constituindo atualmente o estado da arte em termos de métodos de aprendizagem de máquina.⁹²⁻⁹³

4.3.1 Máquinas de Vetores de Suporte (SVM)

Introduzidas oficialmente em 1992 por Vapnik⁹⁴ e aprimoradas desde então, as Máquinas de Vetores de Suporte constituem um algoritmo classificador supervisionado calcado no aprendizado estatístico, apresentando uma sólida fundamentação teórica e excelentes características^{80-81,88} que o tornaram um dos algoritmos mais populares em aprendizagem de máquina, principalmente por demonstrar, em geral, performance significativamente superior em muitas tarefas quando confrontados com outros métodos.^{85,89} Tem sido deveras aplicado em um grande domínio de aplicações incluindo, além da visão computacional, áreas como o processamento de sinais, multimídia, autenticação/segurança, detecção de falhas, bioinformática e entre outros.⁸⁴

Dados dois conjuntos de pontos (duplas no formato $(X_1, X_2, \dots, X_N, Y)$ onde $X_{(i)}$ são os vetores de atributos de entrada da amostra e $Y_{(i)}$ são os atributos de saída $^{\dagger} \in \{+1, -1\}$) linearmente ou não linearmente separáveis, o objetivo de uma SVM é a separação desses dados em duas classes. Para uma simples tarefa de classificação linear de dados perfeitamente separáveis existem potencialmente infinitos hiperplanos[‡] capazes de dividi-los,^{84,87,95-96,98} como ilustrado pela Figura 4.1 - (a).

Ao mover paralelamente quaisquer destes hiperplanos em ambas as direções até deparar-se com algum elemento de cada classe estabelecer-se-á uma faixa ou margem

^{*} Do inglês, *Convolutional Neural Network*.

[†] A literatura sobre SVM utiliza de forma generalizada os atributos “+1” e “-1” para discriminar as classes.⁹⁸

[‡] Hiperplano é um conceito em geometria. É a generalização do plano em diferentes números de dimensões. Um hiperplano pode ser um espaço vetorial, transformação afim ou o sub-espaço de dimensão $n-1$. Em particular, num espaço tridimensional um hiperplano é um plano habitual. Num espaço bidimensional, um hiperplano é uma reta. Num espaço unidimensional, um hiperplano é um ponto. Fonte: <https://pt.wikipedia.org/wiki/Hiperplano>

caracterizada por dois hiperplanos paralelos que separam as duas classes. Ancorada em teoremas matemáticos e estatísticos, além de uma dose de aspectos intuitivos, a estratégia do algoritmo SVM é, pois, encontrar um hiperplano tal, denotado como hiperplano ótimo, que proporcione a maior margem possível, isto é, maximize a distância entre as amostras das duas classes (Figura 4.1 - (b)).^{80,87,97}

Figura 4.1 – Mecanismo de classificação baseado em SVM. (a) Exemplos de possíveis hiperplanos passíveis de separar os dois conjuntos de dados destacados. (b) Hiperplano ótimo que maximiza a margem de separação entre os dados.

Fonte: Adaptada de OPENCV.ORG.⁹⁵

O elemento chave em modelos de treinamento com SVM é identificar um conjunto de vetores candidatos a serem os mais indicados para delinear a fronteira de decisão ou função discriminante (hiperplano ótimo).⁸⁴ A estes vetores, que se encontram mais próximos de tal linha fronteira em ambas as classes (anotados em cor sólida na Figura 4.1 - (b)), denota-se o termo “vetores de suporte”, inspirando o nome atribuído ao algoritmo.⁸¹ Os vetores restantes são descartados após a fase de treinamento, de modo que somente os vetores de suporte são utilizados pelo SVM ao atuar como classificador.⁸⁵

Em geral, aplicações do mundo real não apresentam os dados distribuídos de um modo linearmente separável. Ruídos ou amostras rotuladas incorretamente não são incomuns e podem ocasionar a não linearidade do conjunto de treinamento. Nestes casos, um artifício empregado para tentar separar os dados com um mínimo de erros é a adição de variáveis de folga* nos cálculos resultando em uma suavização ou flexibilização da margem†. Como resultado, os vetores indesejados são desconsiderados, ou seja, são lhes permitido violar a

* Do inglês, *slack variable*.

† Do inglês, *soft margin*.

regra da margem mínima. Um parâmetro “C”, denominado de constante de margem suave é utilizado para o ajuste desta margem de separação suavizada, conforme exemplificado na Figura 4.2. Quanto maior o valor desta constante mais estreita é a margem contribuindo para um mínimo possível de erros. Por outro lado, um valor pequeno aumentará a margem permitindo ignorar vetores próximos a ela, ou seja, maior permissão de dados classificados errados.^{84-85,96}

Figura 4.2 - Exemplo de aplicação SVM utilizando classificação com margem suave sobre 20 amostras não linearmente separáveis. (a) Parâmetro $C = 10$. (b) Parâmetro $C = 0,1$. As fronteiras de decisão de ambos os casos (linha cheia) são praticamente idênticas. Em contrapartida, as margens (região definida entre as linhas tracejadas) são bem diferentes: um pequeno C estabelece uma região maior permitindo abranger mais vetores de suporte.

Fonte: KUNG.⁸⁴

Quando os dados de treinamento são linearmente inseparáveis de fato, uma alternativa é realizar um mapeamento não linear dos dados de entrada para um espaço de maior dimensão, suficiente o bastante, no qual as classes tornam-se linearmente separáveis, isto é, onde um hiperplano com função discriminante linear pode ser determinado,^{81,96} como demonstrando na Figura 4.3. Entretanto, a alta dimensionalidade do novo espaço poderia render um custo computacional excessivo ou impeditivo em muitos casos.^{80,85} Para contornar a situação adota-se um artifício conhecido como “truque do *kernel*” que é o uso de um tipo de função apropriada (funções *kernel*, principalmente as polinomiais, gaussianas e sigmoidais*) que aplicadas aos dados no espaço original simplificam a matemática envolvida.^{85-86,88-89,91,98}

* Função matemática muito utilizada em campos como a economia e a computação, por exemplo. O termo advem da forma em “S” do seu respectivo gráfico. Fonte: https://pt.wikipedia.org/wiki/Função_sigmóide

Figura 4.3 - Aplicação SVM para dados linearmente inseparáveis. (a) Espaço original dos dados de entrada mostrando as classes as quais não são linearmente separáveis. (b) Resultado do mapeamento não linear efetuado pela função *kernel* (Φ) do espaço de entrada para o novo espaço de características no qual as duas classes são agora linearmente separáveis.

Fonte: Adaptada de SONKA.⁸¹

Encerrando esta breve discussão sobre SVM um detalhe informado no início deste tópico é aqui retomado. Fora mencionado que este algoritmo lida com classificações binárias. De fato, SVM foi concebido originalmente para separar os dados em duas classes distintas.^{85,89} No entanto, em muitas aplicações práticas há a necessidade de se identificar mais de duas classes.^{96,97} Afortunadamente, o método pode ser estendido facilmente para múltiplas classes ao empregar alguma das diversas estratégias disponíveis, entre elas a “um-contratodos” que é uma das mais usuais para este fim. Trata-se de definir o número de classes do problema sendo cada uma destas classes (fixadas como positivas) treinadas de modo a separá-la de todas as outras restantes combinadas (anotadas como negativas).^{86-89,91}

4.3.2 Aprendizagem Profunda

A aprendizagem profunda compreende uma família de métodos de aprendizagem de máquina, abrangendo redes neurais, modelos probabilísticos hierárquicos e uma variedade de algoritmos de aprendizagem supervisionados e não supervisionados de padrões. Ela permite que modelos computacionais de múltiplas camadas de processamento aprendam e representem dados com múltiplos níveis de abstração.¹⁰² Tais abordagens têm sido extensivamente pesquisadas durante a última década revelando, entre outros resultados

interessantes, o potencial das redes neurais profundas, e em particular as redes convolucionais em aplicações de visão computacional.^{93,103}

A recente onda de interesse nesses métodos deve-se, sobretudo, ao fato de que estes tem demonstrado superar as melhores técnicas até então em várias tarefas, além da abundante quantidade de dados provenientes de diferentes fontes (visual, áudio, médico, social e sensor, etc.) e disponibilizadas na rede mundial de computadores. Outros fatores que trouxeram protagonismo a tais métodos incluem a proeminência da computação em paralelo* que possibilita significativa aceleração do processo de treinamento dos algoritmos e o advento de poderosas bibliotecas que permitem facilitar a integração e programação desses algoritmos em projetos complexos.^{92,102,106}

4.3.2.1 Redes Neurais Artificiais (RNA)

Longe de caracterizarem-se como uma novidade tecnológica, haja vista, as primeiras pesquisas na área datam da década de 40,⁹⁹⁻¹⁰⁰ as redes neurais artificiais trilharam períodos de desenvolvimento intercaláveis de relativo progresso e estagnação desde então, conferindo-las certo grau de maturidade e consolidação, o suficiente para torná-las, atualmente, muito competitivas na resolução de problemas do mundo real quando comparadas aos métodos tradicionais, baseadas geralmente em modelagem estatística.¹⁰¹

Inspiradas no funcionamento do sistema nervoso de seres vivos e possuindo a habilidade de adquirir e reter informação, interagindo e adaptando-se com o meio externo, analogamente ao cérebro humano, uma típica rede neural artificial pode ser definida como um conjunto simplificado de unidades de processamento (os neurônios artificiais nesta representação) responsáveis por processar dados (vetores e matrizes de pesos sinápticos) e propagá-los através de uma malha de interconexão que representa as sinapses artificiais nesta modelagem. Entre os vários modelos propostos nas duas primeiras décadas de pesquisa em RNA, o *perceptron* (Figura 4.4), como fora denominado, é considerado o modelo matemático mais simples de rede por conter uma única camada com um único neurônio, tornando-se base para o entendimento introdutório de RNA's.^{99,101,104}

* Processamento geralmente realizado em GPUs (do inglês Graphics Processing Unit, ou Unidade de Processamento Gráfico) que por possuir mais núcleos que CPUs (do inglês Central Processing Unit, ou Unidade Central de Processamento) lidam melhor com tarefas paralelas. Fonte: http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture8.pdf

Figura 4.4 – Rede neural simples baseada em unidade *perceptron* de camada única, onde: $[x_1, x_2, \dots, x_n]$ são os sinais de entrada, $[w_1, w_2, \dots, w_n]$ são os pesos sinápticos, b é um limiar de deslocamento linear e $f(z)$ é uma função de ativação. Um somador combina os valores da multiplicação de cada entrada (x_i) por um peso (w_i) com o valor de bias (b) de forma ponderada, gerando um sinal de ativação (z) que ao passar por uma função de ativação (utilizada para limitar a saída do neurônio) resulta na saída (y).

Fonte: Adaptada de HAYKIN.¹⁰⁹

As redes neurais baseadas no modelo apresentado acima são consideradas bem limitadas embora possam ser utilizadas em tarefas de classificação de padrões múltiplos linearmente separáveis ao organizá-los em um layout paralelo sendo cada neurônio (um dos nós da rede) responsável por aprender a ativar uma classe específica entre os dados de entrada.¹¹⁰ Por outro lado, se esses neurônios forem unidirecionalmente conectados, de modo que a saída de uma camada se torne a entrada de outra subsequente, ter-se-á uma estrutura denominada *perceptron* multicamadas (Figura 4.5), em que a primeira camada é a de entrada dos dados na rede, as interiores são denotadas de camadas escondidas e a última refere-se à camada de saída.¹⁰⁸

Figura 4.5 - Estrutura de uma rede neural artificial *perceptron* multicamadas.

Fonte: EBERMAM.¹⁰⁸

Uma RNA compõe-se de uma série de processadores conectados (os neurônios), como mencionado anteriormente, em que cada um produz uma sequência de ativações de valor real, sendo os de entrada ativados através de sensores que percebem o ambiente e os demais ativados através de conexões ponderadas de elementos previamente ativos onde alguns podem influenciar o ambiente ao desencadear ações. A aprendizagem ou atribuição de crédito^{*} a neurônios ocultos da rede, neste contexto, consiste em encontrar pesos que fazem a RNA exibir o comportamento desejado e dependendo do problema e de como os neurônios estão conectados, esse comportamento pode exigir longas cadeias de estágios computacionais, onde cada estágio transforma, geralmente, de maneira não linear os valores de ativação agregada da rede.¹⁰⁵

Tal aprendizagem, caracterizada como “profunda” e discutida na subseção seguinte tomando por base um dos modelos de arquitetura mais conhecido e utilizado em visão computacional, baseia-se na atribuição precisa de pesos e créditos aos respectivos neurônios em muitos desses estágios. A diferença entre as RNA’s “superficiais” e as “profundas” reside na forma como se aprende a função de representação da rede: no primeiro caso, a rede busca uma única função que a partir de um conjunto de parâmetros geram os resultados almejados, enquanto que no segundo são utilizadas composições de funções onde cada uma possui seu próprio conjunto de parâmetros e transmite a respectiva saída para a função seguinte.¹⁰³

4.3.2.2 Redes Neurais Convolucionais (CNN)

A arquitetura das redes neurais convolucionais[†] foram inspiradas em pesquisas realizadas por Hubel e Wiesel,¹¹¹⁻¹¹² a partir do final dos anos 50, acerca das estruturas do córtex visual em animais.⁹² Estes trabalhos, que trouxeram o conceito de “campos receptivos” em alusão à decorrente descoberta pelos autores de que células dessa parte do cérebro são responsáveis por detectar a luz a partir de pequenas sub-regiões do campo visual, influenciaram, no início dos anos 80, a proposição do primeiro modelo computacional de rede baseado em tais princípios, batizado como “*Neocognitron*”¹¹³ e considerado como o predecessor das CNN’s.¹⁰⁵ Tal modelo propunha ser um mecanismo não supervisionado de reconhecimento de padrões visuais utilizando transformações de imagens organizadas

^{*} O algoritmo de aprendizagem da RNA (conhecido como *backpropagation*) habilita o cálculo de uma taxa de erro para cada neurônio da camada escondida permitindo assim uma regra de aprendizagem para os respectivos pesos se propagando na rede. Fonte: https://www.cse.msu.edu/~cse802/S17/slides/Lec_09_Feb08.pdf

[†] Também denominadas, abreviadamente, por “*ConvNets*” por muitos autores.

hierarquicamente.¹⁰⁶ Nas décadas seguintes, novos modelos aperfeiçoados foram propostos estabelecendo as arquiteturas modernas de CNN, embora a escassez de grandes conjuntos de dados de treinamento e o insuficiente poder de processamento dos computadores à época limitasse a performance dessas arquiteturas em problemas mais complexos, fatores estes, entretanto, que foram superados nos últimos anos trazendo definitivamente as CNN's para o foco das atenções.¹¹⁴⁻¹¹⁶

A essência de uma CNN é submeter as normalmente consideráveis quantidades de dados de entrada a um conjunto de filtros e ajustes não lineares*, resultando na redução da dimensionalidade da amostragem e obtenção de mapas de características essenciais, abstratas e profundas do conjunto dado, de modo a realizar o reconhecimento de determinados alvos presentes. Nesse sentido, um modelo de aprendizado profundo baseado em tal rede é adequado para processamento de imagens e outros problemas relacionados ao aprendizado de máquina.¹¹⁷ Embora haja variantes de arquiteturas dessas redes relatadas pela literatura, sua estrutura básica, ilustrada na Figura 4.6, consiste em três tipos principais de camadas, responsáveis por diferentes papéis e distribuídas em múltiplos estágios formando uma rede completa.^{102,106,108,114-115}

- **Camadas de convolução** - Constituída por vários e diferentes filtros de pesos (pequenas matrizes denotadas geralmente como *kernels*) que realizam operações de convolução (somatório da multiplicação da matriz n-dimensional de entrada pelo *kernel* ponto a ponto) sobre toda a imagem[†] (Figura 4.7). O resultado é a geração de um conjunto de mapas de características (atributos específicos como reta, curva, cor, etc.) de dimensões ligeiramente menor que a imagem original (descartam-se as bordas) que preservam os atributos principais dessa imagem;
- **Camadas de pooling** - Também denotadas por camadas de sub-amostragem ou agrupamento, operam semelhantemente às camadas convolucionais, porém utilizando *kernels* sem pesos (operações como a extração do maior valor ou a média em relação aos valores das regiões abrangidas durante o deslizamento do filtro). São responsáveis por reduzir as dimensões dos mapas de características gerados na etapa anterior e de outros parâmetros da rede, enfatizando em maior profundidade as características

* Trata-se da função de ativação usada para adicionar não linearidade à rede. Uma das mais amplamente utilizadas em redes neurais atualmente é a denominada RELU (unidade linear retificada) definida como $f(x) = \max(0, x)$. Fonte: <http://deeplearningbook.com.br/funciao-de-ativacao/>

[†] Por tratar-se de redes neurais convolucionais e sua íntima ligação com o campo da visão computacional amplamente conotada pela literatura, estabelece-se de forma implícita que os dados operacionalizados por tais redes são os pixels de uma imagem a qual pode ser colorida, em escala de cinza, multicanais, etc.

detectadas, além de contribuir para um menor custo computacional, similarmente à etapa anterior, e controlar o sobre-treinamento (*overfitting*) da rede (Figura 4.8);

- **Camadas totalmente conectadas** - Formadas basicamente por redes neurais multicamadas tradicionais em que as respectivas entradas são obtidas via conversão dos mapas de características produzidas anteriormente na etapa de *pooling* em um vetor unidimensional. Com base nestas entradas, que representam a extração das características mais proeminentes da imagem, estas últimas camadas da rede produzem saídas que correspondem a classificação da imagem em várias classes.

Figura 4.6 - Arquitetura de uma rede neural convolucional (CNN). Neste exemplo a rede é utilizada para classificar dígitos escritos à mão. A entrada da rede é uma imagem de 28x28x1 (altura, largura, profundidade) a qual passa por duas convoluções utilizando filtros de 5x5x1 com as suas respectivas camadas de *pooling* 2x2, resultando em um conjunto final de mapas de atributos que são então comprimidos em um único vetor perfazendo a entrada de uma rede neural densa (totalmente conectada).

Fonte: Adaptada de TOWARDS DATASCIENCE.¹¹⁸

Figura 4.7 - Exemplo de um processo de convolução em uma CNN. Um *kernel* de 2x2 desliza sobre a matriz que representa os valores de uma imagem de 3x3, computando o resultado da soma dos produtos ponto a ponto. O resultado final é uma matriz reduzida contendo um mapa de características da imagem original.

Fonte: Adaptada de EBERMAM.¹⁰⁸

Figura 4.8 - Exemplo de um processo de uma camada de *pooling* em uma CNN. Um *kernel* de 2x2 desliza sobre a matriz de uma imagem 4x4 (o mapa de característica obtida pela camada de convolução) computando o maior valor (comumente chamada de *maxpooling*) contido na área abrangida pela sobreposição das matrizes numa nova matriz de atributos. A redução da dimensionalidade neste processo é bastante notável.

Fonte: Adaptada de EBERMAM.¹⁰⁸

Com a utilização desses filtros, aplicados na imagem como um todo, ocorre o compartilhamento de parâmetros que permite o aprendizado de um único conjunto deles localmente ao invés de conjuntos separados, implicando em uma melhor performance desse tipo de rede quando comparadas às tradicionais ANN's. O compartilhamento de parâmetros

traz ainda uma propriedade muito interessante chamada equivariância, que consiste na seguinte premissa: sempre que a entrada é alterada, a saída é alterada da mesma forma. Consequentemente, menos parâmetros são necessários para uma CNN em comparação com outros algoritmos tradicionais de ANN. Quanto ao procedimento de treinamento de uma CNN, este é semelhante ao de uma ANN padrão utilizando o algoritmo de retro propagação. Inicialmente, as informações são propagadas à frente na rede através das camadas, carregando os valores obtidos via filtros e então os valores da saída são computados. Na sequência, o erro entre os valores esperados e os reais é calculado e retro propagado objetivando minimizá-lo e assim, a matriz de pesos é ajustada. No caso da CNN, necessita-se apenas treinar os filtros, ao contrário das ANN's nas quais necessita-se definir os parâmetros.¹⁰⁶

5 MATERIAIS E MÉTODOS

5.1 CLASSIFICAÇÃO E DELIMITAÇÕES DA PESQUISA

O presente trabalho, conforme exposto no primeiro capítulo, objetiva-se, principalmente, por apresentar estratégias de otimização e customização do inovador e ainda custoso processo de deposição de materiais metálicos em pó a laser. Com este intento, optou-se por tomar algumas técnicas de processamento digital de imagens da área de visão computacional, além de modernos algoritmos de aprendizado de máquina frutos de pesquisas em inteligência artificial e embarcá-los em um sistema eletromecânico convenientemente projetado e adaptado, constituindo, assim, o universo da pesquisa realizada. Todo o aparato experimental desenvolvido, longe de constituir-se um sistema profissional em si, haja vista a complexidade e as especificidades de sistemas de deposição reais, isto é, comerciais, prestou-se unicamente à prova de conceito das estratégias adotadas na pesquisa.

De acordo com o enfoque e as técnicas abordadas, este trabalho possui uma natureza aplicada, por focar em soluções para problemas específicos, e uma abordagem predominantemente qualitativa por priorizar uma análise interpretativa dos dados alcançados. Do ponto de vista de seus objetivos, a pesquisa é experimental e exploratória por, respectivamente, partir da definição de um objeto de estudo, escolha das variáveis passíveis de influenciá-lo e delineamento das formas de controle e observação dos efeitos que estas provocam, e por visar uma maior familiaridade com temas marcadamente atuais.

Esta última característica faz com que o trabalho, naturalmente, incorpore alguma forma de pesquisa bibliográfica, servindo como embasamento teórico para o norteamto do desenvolvimento da dissertação. Nesse sentido, realizou-se, inicialmente, um breve estudo dos temas presentes no trabalho com base na literatura disponível, com a ressalva, no entanto, de não se esgotar o assunto, dado que sua amplitude extrapola os principais objetivos anteriormente elencados para essa pesquisa.

5.2 ARRANJO EXPERIMENTAL

De um modo geral, um sistema completo de *Laser Cladding*, consiste de uma fonte de raio laser de potência, de um conjunto alimentador de pó com bocal de distribuição e de um dispositivo de posicionamento controlado por software, além do sistema de controle do equipamento. Nos próximos tópicos do trabalho são descritos todo o arranjo experimental desenvolvido para este projeto, visualizado na Figura 5.1.

Figura 5.1 - Arranjo experimental do sistema de deposição de materiais metálicos desenvolvido para o projeto.
Fonte: Elaborada pelo autor.

5.2.1 Sistema de Posicionamento

Foi desenvolvida uma plataforma de movimentação para controlar três eixos (XYZ) utilizando motores de passo (modelo: SM1.8-D30-CS)¹¹⁹ e seus respectivos módulos (drivers) de controle e potência (modelo: DR-SB050DC04-CS),¹²⁰ ambos fornecidos pela empresa *Action Technology*®. Robusto e possuindo a capacidade de acionar motores de passo com uma

resolução de até 51.200 passos por revolução, tal sistema, com esta precisão e os 3 graus de liberdade em termos de movimento possíveis, permite realizar a deposição dos pós metálicos em superfícies predominantemente planas e com alturas variáveis, satisfazendo plenamente as necessidades do projeto.

A Figura 5.2 apresenta a plataforma desenvolvida no qual o eixo X corresponde a movimentação única da mesa de apoio onde se posiciona a peça a ser revestida e os eixos Y (juntamente com o eixo X perfazem a movimentação bidimensional do sistema) e Z (responsável pela movimentação vertical ou de altura do sistema) ditam a movimentação do cabeçote onde são instalados a fonte de raio laser cujo feixe é focalizado por uma lente (raio incidente 90° em relação ao plano XY), a câmera com o seu sistema de iluminação, o sensor de distância a laser e o injetor de pó (estes itens são descritos mais à frente neste trabalho). O sistema passou por um rigoroso processo de ajustes e calibração dos respectivos eixos para garantir a precisão desejada.

Figura 5.2 - Sistema de movimentação XYZ desenvolvido para o sistema de deposição do projeto.
Fonte: Elaborada pelo autor.

5.2.2 Fonte de Raio Laser

Primordial no projeto, a fonte de raio laser utilizada refere-se ao modelo 70W EP-Z *Pulsed Fiber Laser G4*,¹²¹ produzido pela empresa *SPI Lasers*[®] (Figura 5.3). Trata-se de um laser de fibra cuja potência média de saída nominal pode alcançar 70W (vide especificações na Tabela 1) podendo operar tanto em modo CW (contínuo) quanto pulsado, agregando versatilidade ao projeto.

Figura 5.3 - Fonte de raio Laser utilizado no projeto (modelo 70W EP-Z *Pulsed Fiber Laser G4* da *SPI Lasers*[®]).
Fonte: Elaborada pelo autor.

Tabela 1 - Principais Especificações do Laser modelo 70W EP-Z Pulsed Fiber Laser G4 da SPI Lasers.

Parâmetro	Unidade	Valor
Potência de saída média	W	70
Energia por pulso	mJ	> 1.0
Tempo de largura de pulso	ns	9 - 500
Taxa de repetição	KHz	1 - 1000
Comprimento de onda	nm	1059 - 1065
Fator M^2	-	< 1.6

Fonte: Adaptada de SPI LASERS.¹²¹

5.2.3 Sistema de Injeção de Pó

Foi construído um conjunto que compõe o sistema de injeção de pó metálico do protótipo de bancada. Trata-se de uma parte crítica e complexa do projeto sendo, por esta razão, utilizado modelamento computacional para o desenvolvimento deste item do sistema. Utilizando o software SolidWorks® simulou-se um sistema de transporte do pó do alimentador para o bocal de injeção baseado no conceito de pressão negativa: o pó é sugado para uma tubulação onde uma corrente de gás o transporta em direção ao bocal de saída.¹²² Explicado pelo Princípio de Bernoulli,¹²³ o conceito baseia-se no efeito de Venturi¹²⁴ em que um fluido passando por uma zona de estreitamento aumenta sua velocidade e consequentemente reduz sua pressão produzindo uma região de baixa pressão neste local do duto conforme ilustrado na Figura 5.4.

Figura 5.4 - Esquema do efeito de Venturi adotado para o sistema de alimentação e injeção de pó do projeto.

Fonte: WIKIPÉDIA.¹²⁴

Para realizar esse papel de produzir uma função de vácuo, tal como exemplificado acima, a fim de realizar a mistura e o transporte do pó ao duto de injeção, foi utilizada uma válvula geradora de vácuo pneumática¹²⁵ cuja instalação no sistema de deposição é apresentada na Figura 5.5.

Figura 5.5 - Válvula geradora de vácuo responsável por realizar o transporte do pó do alimentador ao injetor do sistema.

Fonte: Elaborada pelo autor.

O gás utilizado para o transporte das partículas de pó nos testes (Figura 5.6) refere-se ao Argônio, um gás inerte, cuja utilização impede o processo de formação de óxidos indesejáveis durante a deposição/fusão do pó metálico na superfície do substrato devido à clara diminuição da quantidade de oxigênio participante desses processos químicos/metalúrgicos ocorridos no procedimento.

Figura 5.6 - Sistema de fornecimento de gás para o sistema de deposição (Cilindro de gás Argônio montado com registro de abertura principal, secundário, manômetros e válvula de segurança).

Fonte: Elaborada pelo autor.

A Figura 5.7 apresenta o aparato da alimentação do pó, um sistema misto, versátil e de bom custo-benefício baseado em gravidade e transporte por rosca o qual foi desenvolvido para o projeto. Utilizou-se um pequeno motor de passo acoplado a uma rosca sem fim capaz de realizar um transporte preciso de uma pequena quantidade de pó a partir de um reservatório superior (o pó cai por gravidade sobre a rosca que o transporta até um orifício em direção a um compartimento onde um leve fluxo de gás entrante se mistura com este pó, sendo em seguida atraído à válvula de vácuo pela atuação desta).

Figura 5.7 - Aparato de alimentação de pó desenvolvido para o sistema de deposição.
Fonte: Elaborada pelo autor.

Com relação ao bocal de pulverização do pó, optou-se pelo modelo de injeção lateral (visualizado na Figura 5.8), suficiente para os propósitos deste projeto.

Figura 5.8 - Bico injetor de pó metálico tipo lateral do sistema de deposição desenvolvido.
Fonte: Elaborada pelo autor.

5.2.4 Controle do Sistema (Hardware)

O controle do sistema é realizado por um módulo ou placa modelo *Raspberry Pi 3*.¹²⁶ Trata-se de um minicomputador embarcado de baixo custo desenvolvido pela fundação britânica *Raspberry Pi Foundation*¹²⁷ com a intenção difundir e estimular o estudo da área da ciência da computação no âmbito educacional. Possuindo basicamente a maioria dos recursos disponíveis em um PC normal e uma série de atributos vantajosos (baixo custo, baixo consumo de energia, portátil, *plug-and-play* para muitas tarefas, entre outros), a *Raspberry Pi 3* (Figura 5.9) credenciou-se como uma opção viável para a tarefa de controlar o sistema de deposição de metais a laser do projeto.

Figura 5.9 - Placa de controle modelo *Raspberry Pi 3* utilizada no projeto.
Fonte: Elaborada pelo autor.

A *Raspberry Pi 3* possui um barramento de portas de sinais digitais de entrada/saída com diversas funções (40 pinos) além de conectores USB, HDMI e ETHERNET permitindo muita flexibilidade ao projetista. No caso deste projeto, por exemplo, tem-se os seguintes acionamentos mapeados por este embarcado:

- Drivers (placa de controle e alimentação dos motores de passo) do sistema de movimentação XYZ (sinais de pulso e direção);
- Controle dos parâmetros da fonte de raio laser (via comunicação serial);
- Leitura dos sensores de fim de curso dos eixos de movimentação;
- Leitura do sensor de distância a laser;
- Controle do misturador e ejeção de pó metálico;
- Câmera e iluminação;
- Periféricos (mouse, teclado e monitor).

O controle de deposição do sistema, como será detalhado posteriormente, utiliza visão computacional para identificar as regiões de interesse da peça as quais devem receber os depósitos. Em outras palavras, o sistema é capaz de identificar uma fissura ou parte danificada, por exemplo, e se auto direcionar para preenchê-las com o material de adição. Para tanto é utilizado um módulo de câmera (sensor Sony IMX219 de 8 MP de resolução),¹²⁸ acessório este, compatível com a placa *Raspberry Pi 3*, que realiza a captura de imagem da superfície da peça a ser trabalhada, enviando à placa de controle a qual realiza o processamento. Esta câmera (Figura 5.10) possui uma boa resolução, baixo custo e fácil instalação tornando-a uma boa alternativa para o projeto.

Figura 5.10 - Módulo de câmera empregada pela placa de controle *Raspberry Pi 3*.

Fonte: RASPBERRY PI FOUNDATION.¹²⁸

No caso deste projeto a câmera foi instalada de forma embutida na parte central de uma luminária LED luz branca difusa e formato tipo *Plafon* (Figura 5.11). Pelos testes realizados com uma série de tipos de iluminação concluiu-se que este tipo utilizado foi a opção melhor uma vez que é de fácil instalação e diminui os problemas de reflexão.

Figura 5.11 - Sistema de iluminação com a câmera da *Raspberry Pi 3* embutida.
Fonte: Elaborada pelo autor.

O controle é realizado em malha fechada, sendo um sensor de distância a laser de precisão o responsável pelo fechamento do elo de controle. Este sensor deve possuir uma alta resolução a fim de detectar com margem de segurança as eventuais irregularidades da superfície da peça (trincas, depressões, rugosidades, protuberâncias, etc.) que devem receber o revestimento (ligar / desligar o laser nessas áreas), bem como informar ao controle do sistema e este ao sistema de movimentação (eixo Z) em tempo real acerca do perfil da superfície do objeto em questão, de modo a manter o foco do raio laser incidente a uma distância fixa da superfície de trabalho. Idealmente, o foco deve estar na superfície do substrato, de tal sorte que toda a energia do laser possa ser aproveitada, além de ganhos de produtividade e

qualidade. O sensor incorporado ao projeto e que realiza esta tarefa é modelo HG-C 1100¹²⁹ da empresa Panasonic® (Figura 5.12). Trata-se de um micro sensor a laser de deslocamento com saída analógica possuindo faixa de medição 100mm +/-35mm e repetibilidade de 70µm.

Figura 5.12 - Sensor de distância a laser selecionado para o projeto (modelo HG-C1100 da Panasonic®).
Fonte: Elaborada pelo autor.

5.2.5 Montagem Elétrica

A parte elétrica/eletrônica do sistema de deposição (resumida no diagrama elétrico da Figura 5.13) conta com algumas placas de circuito impresso que realizam todos os controles do equipamento protótipo, além de todas as conexões elétricas pertinentes. O sistema elétrico foi acondicionado parte em bancada (controle de interface do módulo laser e sua respectiva fonte de alimentação) e a outra em um gabinete apropriado fixado à estrutura mecânica do protótipo (visualizado na Figura 5.14). Neste painel encontram-se instalados os drivers dos

motores de passo, circuitos de interface de potência e sinal, a placa *RaspBerry Pi* e as demais fontes de alimentação dos circuitos utilizados.

Figura 5.13 - Diagrama elétrico do sistema de deposição a laser.

Fonte: Elaborada pelo autor.

Figura 5.14 - Gabinete elétrico do sistema de deposição do projeto.
Fonte: Elaborada pelo autor.

5.3 SOFTWARE DE CONTROLE DO SISTEMA

Baseado em controle por malha fechada, visão computacional e aprendizagem de máquina, o sistema permite um processo de revestimento a laser inteligente. Como anteriormente mencionado, um mini PC modelo *Raspberry Pi 3*, dotado de um sistema operacional (*Raspbian*)^{*}, aplicativos e bibliotecas instalados ou compilados, está sendo utilizado para realizar esta tarefa. A seguir serão discriminadas algumas dessas ferramentas utilizadas e na sequência as estratégias por elas realizadas.

5.3.1 Ferramentas Computacionais Adotadas

Foram instaladas no hardware de controle várias bibliotecas voltadas ao desenvolvimento de aplicações em visão computacional, aprendizagem de máquina e

^{*} O sistema operacional *Raspbian* é uma distribuição Linux criada para rodar nas placas *Raspberry Pi*. É considerado o sistema operacional padrão dos hardwares distribuídos pela *Raspberry Pi Foundation* (a placa permite rodar outros sistemas). Possuem diversos softwares de desenvolvimento, controle total sobre o hardware da placa, além de ferramentas de acesso à Internet e de entretenimento. Fonte: <https://www.techtudo.com.br/tudo-sobre/raspbian.html>

manipulação de dados, essenciais para a concretização dos objetivos do projeto. Tais bibliotecas são compatíveis com a linguagem Python 3 a qual foi adotada para desenvolver todos os algoritmos de controle do sistema e é padrão para utilização nos módulos *Raspberry Pi*. As principais utilizadas no desenvolvimento do software foram:

- **OpenCV (*Open Source Computer Vision Library*)** - Desenvolvido inicialmente pela empresa Intel® em 1999, trata-se de um conjunto de módulos multiplataformas (além da linguagem C++ que é nativa, possui suporte a outras como Python e Java, por exemplo) de processamento de imagens e vídeo, controles de periféricos e uma série de algoritmos (mais de 2500 até a presente data) de visão computacional e aprendizagem de máquina disponibilizados de forma gratuita para download a todos os desenvolvedores;¹³⁰
- **Dlib** - Biblioteca de código aberto multiplataforma também escrita nativamente em C++, porém estendida a outras linguagens por meio de *wrappers**, tal qual o OpenCV. Desenvolvida a partir de 2002 pioneiramente por Davis King, esta coleção de algoritmos e ferramentas, consideradas mais eficientes que o OpenCV em muitos casos, destina-se a uma enorme gama de aplicações incluindo aprendizado de máquina, processamento de imagens, interfaces gráficas, estruturas complexas de dados, álgebra linear, mineração de dados, análise de texto e várias outras tarefas, garantindo-lhe, por esta razão, uma conotação mais comercial.¹³¹
- **TensorFlow** - Multiplataforma poderosa e completa de código aberto para desenvolvimento e treinamento de modelos de aprendizado de máquina e computação numérica. Desenvolvido pela empresa Google®, popularizou-se por constituir-se um ecossistema abrangente e flexível de ferramentas, bibliotecas e uma comunidade ativa que tem permitido constantes avanços a este framework que é considerado o estado da arte neste segmento na atualidade. O termo “TensorFlow” vem do fato de que esta ferramenta computacional se baseia na criação de grafos de fluxo de dados (*flow*) onde tais dados podem apresentar-se de diversas formas (escalar, vetor ou matriz multidimensionais) sendo dado o conceito de tensor à generalização dessas estruturas.¹³²

* *Wrappers* são funções destinadas a chamar uma ou mais funções. No caso aqui abordado, a ideia é usar funções em uma dada linguagem para acessar as classes escritas em outra linguagem.

Além dessas listadas acima e outras auxiliares utilizadas, empregou-se outras ferramentas externamente, isto é, em outro ambiente de desenvolvimento (diferente da *Raspberry Pi*) como o Qt Designer¹³³ empregado para a criação da interface de usuário para o controle do sistema de deposição desenvolvido (ilustrada no próximo tópico).

5.3.2 Método de Controle Inteligente Desenvolvido

Os algoritmos responsáveis pelo controle do sistema foram desenvolvidos de forma que o programa por meio de uma interface gráfica amigável desenvolvida especialmente para o projeto (Figura 5.15) interaja com o usuário em determinadas etapas e opere automaticamente em outras, perfazendo uma sequência esquematizada na Figura 5.16 e detalhada nas próximas subseções. Também será objeto de análise os processos de obtenção dos algoritmos treinados, responsáveis pela tarefa de detecção e reconhecimento de padrões nas superfícies metálicas pesquisadas.

Figura 5.15 - Interface gráfica desenvolvida para o sistema de deposição de materiais a laser.

Fonte: Elaborada pelo autor.

Figura 5.16 - Fluxograma do método de controle desenvolvido.
Fonte: Elaborada pelo autor.

5.3.2.1 Posicionamento da Área de Trabalho e Captura da Imagem

O primeiro passo do processo desenvolvido é o posicionamento correto do cabeçote do protótipo de modo a se obter sempre uma referência fixa em relação à imagem da área a ser trabalhada. Para isso, os eixos são primeiramente referenciados por sensores (tipo micro switch) fixos em suas respectivas extremidades (fim-de-curso). Na sequência é dado comando para os eixos se posicionarem ao centro da plataforma de trabalho, onde a peça a ser submetida ao processo de deposição deve ser devidamente assentada, e então o laser guia do módulo fonte de raio laser é acionado (se a superfície da peça for irregular recomenda-se, com a ajuda do laser guia, posicionar o objeto de forma que o ponto mais inferior de sua superfície esteja nessa posição central). Em seguida um comando de “Buscar foco laser” faz com que o eixo de altura do sistema (Z) se movimente em direção à superfície do alvo até que, baseado na leitura do sensor de distância a laser, o sistema capture automaticamente a coordenada do ponto ótimo para o processo de fusão dos materiais (distância focal) tal como ilustrado na Figura 5.17.

Figura 5.17 - Ajuste da distância ótima de operação (foco do raio laser incidente) entre o cabeçote de deposição e a superfície da peça a receber o depósito utilizando um preciso sensor de distância a laser.

Fonte: Elaborada pelo autor.

Após este último evento, um comando reposiciona os eixos para uma determinada coordenada fixa por convenção (posição de visada da área útil de trabalho em relação à plataforma) e então a câmera do sistema é ligada e uma janela mostra imagens em tempo real da superfície de trabalho (Figura 5.18). O próximo passo é o envio do comando de “Capturar” o qual fará com que se capture um frame da imagem, abrindo uma nova janela na qual o usuário apontará a região delimitada de interesse, isto é, alvo para receber a deposição, como demonstrado no próximo tópico.

Figura 5.18 - Campo de visão da área de trabalho do sistema a partir da câmera da *Raspberry Pi* instalada no cabeçote de deposição. Neste exemplo, observa-se a captura da imagem de uma régua esquadro assentada sobre a plataforma para uma simples referência.

Fonte: Elaborada pelo autor.

5.3.2.2 Seleção da Região Desejada e Pré-processamento da Imagem

A partir da imagem capturada, com o auxílio do mouse seleciona-se a região de interesse (ROI)* referente à região limítrofe total ou macro onde o sistema estará apto a investigar a superfície (etapa de detecção e reconhecimento de características descrita no próximo item) e posteriormente realizar o depósito (Figura 5.19). Após a seleção uma janela com a imagem dessa área é mostrada permitindo avaliar se a região foi selecionada corretamente. Em caso negativo (usuário tecla “ESC”), o processo de seleção poderá ser

* Do inglês, *Region Of Interest*. Termo bastante recorrente na área de processamento de imagens.

repetido, caso contrário (usuário tecla “ENTER”) a imagem passará por processos de filtragem e aprimoramentos para melhor prepará-la para a etapa seguinte.

Figura 5.19 - Seleção (via mouse) da região da peça candidata a receber o depósito. A área passará pela análise do software que determinará em quais subáreas será realizado o processo.

Fonte: Elaborada pelo autor.

Esse processo de filtragem consiste basicamente em submeter a imagem recortada, previamente transformada em escala de cinza, a filtros específicos de forma a mitigar os efeitos de ruídos e salientar determinados aspectos desejáveis, além de diminuir a quantidade de informação da imagem (imagens coloridas possuem mais canais que as de cinza) o que pode impactar positivamente nos resultados dos algoritmos de detecção. Dentre vários tipos de filtros pesquisados, dois deles foram adotados por apresentarem os melhores resultados (exemplificados na Figura 5.20):

- **Filtro de Gabor** - São filtros lineares sensíveis capazes de extrair características de diferentes orientações, escalas e níveis de suavidades em uma imagem. Por possuir propriedades de localização ótima no domínio espacial e de frequência, têm sido utilizados em muitas aplicações, sendo adequados, por exemplo, para problemas de

segmentação de textura. Basicamente, um filtro desse tipo, parametrizado em uma dada direção específica, fornece uma forte resposta apenas para os locais na imagem onde há estruturas com a direção condizente com este filtro;¹³⁴

- **Filtro *Non-Local Means* (NLM)** – Considerado um método de filtragem desenvolvido mais recentemente, o filtro NLM baseia-se no simples princípio da similaridade de pixels. O algoritmo do filtro substitui o valor de um pixel considerado ruidoso por uma soma ponderada dos valores dos pixels em toda a imagem, sendo o peso de cada pixel determinado pela semelhança entre a vizinhança do pixel e a do pixel ruidoso.¹³⁵

Figura 5.20 – Resultados do processo de filtragem em imagens utilizando os dois tipos de filtros selecionados para o projeto. (a) Imagem original. (b) Filtro *NonLocalMeans*. (c) Filtro *Gabor*.

Fonte: Elaborada pelo autor.

O resultado do processo de filtragem realizado pelos algoritmos acima é apresentado na tela do usuário e estando dentro de padrões esperados ou aceitáveis (avaliação um tanto subjetiva, porém intuitivamente confiável) pressiona-se o “ENTER” e a imagem será submetida aos algoritmos treinados e especializados de aprendizagem de máquina que detectarão um conjunto de padrões pré-definidos na imagem. Por outro lado, se o resultado da filtragem não se apresentar satisfatório, pode-se repetir o processo mediante a tecla “ESC” (além de ajustes nos parâmetros dos filtros, em certos casos específicos, o reposicionamento da peça em outro ângulo ou uma melhor limpeza da superfície podem melhorar consideravelmente os resultados, lembrando que para essas duas últimas alternativas, uma nova captura da imagem deverá ser realizada).

5.3.2.3 Extração de Padrões da Imagem

Nesta etapa são utilizados algoritmos pré-treinados para realizar o reconhecimento de determinadas características presentes na superfície do objeto metálico sobre o qual deseja-se

depositar o material em pó de interesse. A enorme lista de possibilidades que podem ocorrer nessas superfícies, desde as problemáticas como arranhões, trincas, desgastes e defeitos, até as de natureza normal como ressaltos, rebaixos, parafusos, rebites, fendas, juntas, orifícios, logotipos, escritos, placas de identificação e códigos de rastreamento (barras, *QR Code*, *Data Matrix*, etc.), torna a tarefa de simultaneamente detectar e reconhecer automaticamente tais atributos algo extremamente desafiante.

Pela razão acima apontada, optou-se por atacar o problema em duas frentes e também restringir a quantidade de tipos de elementos detectáveis: para um número fixo de padrões específicos e caracteristicamente bem definidos, adotados para o projeto, foi-lhes endereçado o algoritmo SVM, enquanto que para os atributos cujas características são notadamente variantes, aleatórios ou mesmo imprevisíveis (conjunto de problemas e avarias presentes na superfície), redes neurais convolucionais, que constituem uma abordagem mais moderna, robusta e poderosa, foram empregadas.

5.3.2.3.1 Detecção de padrões específicos na superfície empregando SVM

Foram selecionados alguns padrões (Tabela 2) tais que se objetiva que o sistema de visão desenvolvido possa reconhecê-los em qualquer imagem por este captada. Para tanto, rotinas de treinamento foram executadas empregando imagens aleatórias de tais padrões (Figura 5.21) de modo a obter-se os algoritmos capazes de realizar esse trabalho de detecção a posteriori. Este processo consistiu nas seguintes etapas:

- **Seleção de imagens** - Escolheu-se um conjunto de imagens contendo os padrões desejados sendo que as mesmas foram alocadas em pastas separadas de acordo com o padrão alvo apresentado;
- **Anotação ou rotulagem dos padrões de interesse na imagem** - As pastas criadas com as respectivas imagens são carregadas por um aplicativo gráfico (Imglab.exe), pertencente ao pacote de ferramentas da biblioteca Dlib. Pela interface deste, selecionou-se, em cada imagem, a região em torno do objeto alvo com o auxílio do mouse (Figura 5.22). O aplicativo gera ao final do processo um arquivo (extensão .xml; um por pasta analisada), cujo conteúdo são as coordenadas captadas pelo programa referente às regiões selecionadas de cada imagem;

- **Treinamento** - Os arquivos XML gerados foram submetidos ao treinamento do algoritmo, cuja rotina baseia-se internamente em cálculos envolvendo SVM's e é efetuada em ambiente de programação Python. Ao final de execução da rotina (uma para cada arquivo XML) é gerado o algoritmo classificador (extensão .svm) que está pronto para ser utilizado em rotinas de detecção dos referidos padrões.

Tabela 2 - Especificação dos padrões característicos selecionados para o projeto e os respectivos treinamentos.

Padrão Característico Selecionado	Qtd. de Imagens (Treinamento)	Qtd. de Imagens (Teste)	Acertos de Detecção (%)
Logotipo de empresa	5	5	100
Orifício circular	8	10	80
QR Code	6	7	90

Fonte: Elaborada pelo autor.

Figura 5.21 - Algumas das imagens contendo determinados padrões (logo de empresa, orifício e QR Code) as quais foram utilizadas para o treinamento dos algoritmos de detecção produzidos para o projeto.

Fonte: Elaborada pelo autor.

Figura 5.22 - Aplicativo Imglab utilizado para anotação de objetos de interesse em imagens para treinamento dos algoritmos de aprendizagem de máquina.

Fonte: Elaborada pelo autor.

Os arquivos de treinamento obtidos foram submetidos a testes utilizando um conjunto de novas imagens (Figura 5.23). Analogamente à etapa de treinamento, foram criadas pastas contendo imagens com a presença dos mesmos padrões distintos e característicos treinados. A partir de tais aferições, ajustes em parâmetros da rotina de treinamento foram realizados, permitindo, após algumas repetições, obter-se os algoritmos finais utilizados pelo sistema. A Figura 5.23 apresenta algumas imagens obtidas durante a etapa de testes dos algoritmos de detecção produzidos.

Figura 5.23 - Testes de detecção de padrões característicos selecionados para o projeto em imagens aleatórias utilizando os algoritmos treinados obtidos.

Fonte: Elaborada pelo autor.

5.3.2.3.2 Detecção de defeitos na superfície da amostra empregando CNN

A detecção de características envolvendo padrões de defeitos nas superfícies de metais é uma tarefa complexa a julgar pela variabilidade em termos de formas e tamanhos que estes podem aparentar, além de outros aspectos extrínsecos e intrínsecos envolvidos como, respectivamente, a iluminação da amostra pelo sistema de visão do sistema (superfícies comumente reflexivas) e as características de cada tipo de material (diferentes tipos e aspectos de oxidação que podem ocorrer nessa superfície e o seu respectivo grau de polimento). Há ainda a questão da indisponibilidade de uma base ampla de imagens especialmente rotuladas* com tais características, necessária para a implementação de algoritmos de detecção supervisionados que contemplem todos os possíveis defeitos mapeados pela literatura com um mínimo de acurácia desejada.

Dada essa dificuldade de obtenção de imagens rotuladas para o propósito deste projeto, optou-se por utilizar uma base de dados conhecida como NEU-DET,¹³⁶ elaborada e disponibilizada por pesquisadores da *Northeastern University* (China) que publicaram alguns trabalhos¹³⁷⁻¹³⁹ empregando estes arquivos. Trata-se de um conjunto de 1800 imagens referentes a seis tipos de defeitos (Figura 5.24) apresentados em superfícies de aço durante o processo industrial de laminação do metal, além dos arquivos (extensão .xml) contendo as coordenadas dos rótulos obtidos em cada uma dessas imagens. Embora a natureza dos defeitos apresentados por tal conjunto de dados serem particularmente de fabricação, algumas de suas características podem ser transferidas para o caso de avarias decorridos da exposição da superfície do metal ao longo de sua utilização.

* Além da necessidade de se obter imagens com boa resolução contendo o objeto a ser detectado, é preciso anotá-lo na imagem, isto é, selecioná-lo para a obtenção de suas coordenadas e tal procedimento é demasiado custoso em termos de tempo, haja vista que deve ser realizado manualmente em todas as imagens que servirão de treinamento do algoritmo.

Figura 5.24 - Imagens (200x200, escala de cinza) de superfícies metálicas (aço) apresentando seis tipos de defeitos típicos após o processo de fabricação (processo de laminação).

Fonte: NEU-DET.¹³⁶

Baseado em redes neurais profundas do tipo convolucionais, o detector de defeitos em superfícies metálicas utilizado neste projeto foi treinado utilizando a biblioteca do Tensorflow. Este processo de treinamento foi elaborado seguindo uma série de passos, exigidos por esta plataforma de aprendizagem de máquina:

- **Aquisição das imagens de treinamento** – Recomenda-se, de acordo com a documentação do Tensorflow a utilização de no mínimo algumas centenas de imagens para o treinamento de um modelo de detecção, sendo que quanto maior a quantidade tanto melhor será a performance do algoritmo. Para este projeto, como já mencionado no penúltimo parágrafo, foram utilizadas uma base de dados disponível para download na internet. Do total de imagens coletadas, 80% foram destinadas em uma pasta para o

treinamento do algoritmo enquanto as restantes foram direcionadas para os testes que este implementa durante o processo;

- **Rotulagem das imagens** - O processo de rotular uma imagem é o mesmo procedimento já descrito anteriormente (subseção 5.3.2.3.1). Contudo, tal como no passo anterior, os arquivos relacionados a esta etapa também foram disponibilizados no mesmo pacote;
- **Geração dos arquivos de treinamento** - Os arquivos de rótulo (extensão .xml) necessitam serem transformados em um formato compatível com o Tensorflow (TFRecord). Para isso, duas etapas são necessárias: um script escrito em Python converte os arquivos xml em .csv e em seguida uma outra rotina finalmente converte-os no formato requerido (extensão .record);
- **Configuração dos parâmetros de treinamento** - Nesta etapa é criado o arquivo referente ao mapa de classes utilizados (6 no caso do conjunto de imagens utilizados neste projeto) e é realizado a adaptação ou atualização do arquivo de configuração do treinamento, responsável pela definição do modelo utilizado, dos parâmetros de avaliação das fases de treinamento / teste e o estabelecimento dos endereços ou caminhos para os diretórios das imagens utilizadas no processo. Por recomendação é utilizado um modelo pré-treinado disponibilizado, entre uma série de opções em uma lista, pela biblioteca do Tensorflow, o qual é então retreinado levando em conta os parâmetros do detector desejado. Uma das razões para isso é que o treinamento a partir do zero toma uma quantidade considerável de tempo, além do fato que o modelo pré-treinado fora produzido a partir de uma quantidade grande de dados conferindo-lhe bastante confiabilidade. Para este projeto foi adotado o modelo `faster_rcnn_inception_v2_pets.config`;
- **Treinamento** – Uma vez configurado o arquivo de configuração (modelo adaptado com as devidas alterações na etapa anterior) é dado o comando de executar um script de treinamento que dá início ao processo. O tempo de treinamento depende basicamente do poder computacional da máquina empregada no processo e do tamanho da base de imagens utilizada. O processo envolve o cálculo de um índice de perda (*TotalLoss*) que decresce conforme o desenrolar do treinamento sendo que este deve ser finalizado pelo usuário quando se alcançar um valor satisfatório (a taxa de decréscimo do parâmetro se mostra bem lento) para evitar *overfitting*. Tal progresso

pode ser acompanhado por uma interface de visualização (TensorBoard) que faz parte da biblioteca do Tensorflow (Figura 5.25);

- **Geração do modelo** – Completado o treinamento, deve-se exportar o modelo (transformá-la em um grafo de inferência) de modo que este possa ser utilizado nas aplicações desejadas. A chamada de uma linha de comando permite gerar o referido arquivo;
- **Teste do modelo** – Com o detector de defeitos em superfícies metálicas recém-criado foi utilizado um script para testá-lo empregando algumas imagens diversas contendo defeitos (Figura 5.26).

Figura 5.25 - Janela da interface da ferramenta TensorBoard apresentando informações em tempo real sobre o processo de treinamento da rede neural convolucional utilizada para a criação do detector.

Fonte: Elaborada pelo autor.

Figura 5.26 - Imagens de superfícies metálicas com defeitos testadas pelo detector baseado em CNN elaborado para o projeto.

Fonte: Elaborada pelo autor.

5.3.2.4 Averiguação da Detecção e Escolha da Melhor Estratégia

Uma vez que os resultados do processo de detecção são apresentados em imagens na tela, decide-se qual a melhor ação ou simplesmente a desejada a ser tomada pelo sistema (a interface do programa possui determinados parâmetros que o usuário pode selecionar nesse sentido). Uma lista de possibilidades que podem emergir e possíveis tomadas de ação são apontadas na Tabela 3 a seguir.

Tabela 3 - Possíveis resultados da detecção e respectivas ações a serem tomadas.

Resultado da Detecção	Possíveis Ações a Serem Tomadas
Nenhum objeto detectado	<ul style="list-style-type: none"> ✓ Verificar se houve falhas e em caso positivo proceder uma nova captura e/ou tratamento da imagem. ✓ Pode-se apenas utilizar o laser de modo a limpar a superfície e com isso melhorar a acurácia do processo de detecção. ✓ Pode-se querer revestir toda a área selecionada para um objetivo específico sem se importar com o que há na superfície (neste caso, o usuário opta de antemão pelo sistema não proceder a detecção).
Detecção parcial de objetos presentes	<ul style="list-style-type: none"> ✓ Considerar se vale a pena repetir o processo reajustando os parâmetros para detectar todos os padrões presentes. ✓ Avaliar se os padrões estão íntegros (talvez seja uma boa estratégia no caso de código de rastreamento ilegível descartá-los, isto é, depositar sobre eles).
Padrões específicos detectados	<ul style="list-style-type: none"> ✓ Depositar ou não nessas áreas de acordo com o interesse.
Padrões aleatórios detectados (defeitos)	<ul style="list-style-type: none"> ✓ Depositar nessas áreas. ✓ Se forem muitos entes detectados pode ser prudente depositar em toda a região selecionada. ✓ Se houver ranhuras com certa profundidade convém ajustar o sistema para realizar várias camadas na referida região detectada.

Fonte: Elaborada pelo autor.

5.3.2.5 Geração do Mapa de Trajetória

A partir da região selecionada e áreas detectadas circunscritas nessa superfície, os algoritmos do programa modificam os pixels dessas áreas transformando-os em valores binários (preto (0, 0, 0) e branco (255, 255, 255)) de modo a contrastar as regiões a serem depositadas ou não, e assim, o software possa guiar-se por este modelo ligando e desligando o laser/aspersão do pó de acordo com o valor lido ao percorrer toda a área.

A relação entre as dimensões espaciais dos pixels da imagem captada da superfície da peça a ser trabalhada e as dimensões reais desta mesma superfície analisada (coordenadas XYZ) foram estimadas por meio de gabaritos, cálculos de resolução da imagem e respectivas calibrações. Para tanto utilizou-se como referência uma altura fixa da câmera em relação à superfície (obedecendo a distância focal do laser), o ponto central da imagem, as coordenadas absolutas dos eixos do sistema neste ponto e o deslocamento relativo em relação a pontos extremos espacialmente definidos entre si e valores de pixels conhecidos dentro do campo de visão da câmera (gabaritos formados de pontos escuros espaçados com métrica precisa em superfície com fundo branco). Com isto, todos os pontos das imagens obtidas pela câmera a partir de uma posição sempre fixa da plataforma em relação ao referencial zero do sistema se relacionará diretamente com as coordenadas absolutas de seus eixos.

5.3.2.6 Execução da Deposição

Com o estabelecimento das coordenadas espaciais das regiões a serem depositadas e a determinação dos valores “binarizados” dos pixels da imagem dessas áreas o sistema está apto a realizar a execução da tarefa dentro dos limites da área selecionada de trabalho. A Figura 5.27 ilustra a trajetória realizável pelo sistema desenvolvido. Idealmente, as trilhas depositadas são de larguras regulares, bem como o espaçamento entre elas para a obtenção de camadas homogêneas.

Figura 5.27 - Esboço da trajetória de deposição do sistema desenvolvido em relação às coordenadas XYZ.
Fonte: Elaborada pelo autor.

5.3.2.7 Finalização do Processo

Ao finalizar o processo de deposição verifica-se o resultado, podendo, caso seja insatisfatório, repetir o procedimento através de mais camadas depositadas ou reprocessar a peça (lixamento) e reiniciar todo o processo (captura, detecção, etc.). Em caso de sucesso no processo realizado, o software desenvolvido coletará uma série de dados pertinentes ao procedimento ora finalizado (imagens captadas e processadas, coordenadas e características das regiões e objetos detectados, tempos dos processos envolvidos, parâmetros utilizados e tantos outros que podem ser agregados posteriormente) e salvará em banco de dados para futuras implementações e melhorias do próprio sistema.

O banco de dados adotado neste projeto é o MongoDB,¹⁴⁰ orientado à documentos (não relacional), que possui algumas características interessantes: gratuito, multiplataforma, robusto, entre outros, atendendo, portanto, aos objetivos propostos.

5.4 AMOSTRAS E PÓS UTILIZADOS

5.4.1 Amostras de metais

Amostras de aço de diversas especificações (SAE-1020, SAE-8620, 316L, 304, 430) e de alumínio em condições de estado normais (sem polimento refinado ou qualquer tipo de limpeza criteriosa) foram utilizadas de modo a simular situações reais de trabalho (o objetivo é tratar ou recuperar superfícies obviamente).

A Figura 5.28 apresenta um conjunto dessas amostras utilizadas nos testes em que se observam na maior parte delas, gravuras, ranhuras, áreas com manchas e outras deformidades em suas respectivas superfícies, além de marcações artificiais (produzidas a laser) realizadas para simular áreas degradadas a fim de testar os algoritmos utilizados.

Figura 5.28 – Algumas das amostras metálicas (substratos de aço e alumínio de diferentes tipos) utilizadas no projeto.

Fonte: Elaborada pelo autor.

5.4.2 Pós de metais e ligas metálicas

Foram realizados testes com algumas ligas metálicas em pó disponíveis comercialmente:

- Surfit™ 316L – Höganäs;
- Colmonoy 63 – comersul;
- Pó de Níquel (99,8%);
- Durmat 60 AH código-p3001H- Durum do brasil;
- Durmat 1055 P3102 ou tungtec 10112.

5.5 PARÂMETROS GERAIS DO SISTEMA

Os diversos parâmetros utilizados no processo de deposição nos testes realizados para este projeto de pesquisa são resumidos na Tabela 4 a seguir:

Tabela 4 - Principais parâmetros utilizados pelo sistema de deposição durante os testes.

Parâmetro	Unidade	Faixa de Valores
Potência do Laser	W	20 - 70
Modo de operação Laser	-	CW (contínuo) e Pulsado
Velocidade de deposição	mm/seg.	1 - 50
Pressão gás de injeção (Ar)	bar	3 - 10
Diâmetro spot do Laser	mm	0,08
Largura da trilha depositada	mm	0,08
Altura da trilha depositada	mm	0,05
Ângulo entre o bico injetor e a superfície	Grau (°)	30 - 60
Temperatura ambiente	°C	22
Distância entre cabeçote e superfície do alvo (foco)	mm	35
Altura máxima permitida do objeto alvo do depósito	mm	97,5
Deslocamento máximo eixo x	mm	312,5
Deslocamento máximo eixo y	mm	223,5
Deslocamento máximo eixo z	mm	132,5
Resolução das imagens captadas	pixel	1280x720
Área de trabalho LxA (aprox.)	mm	329x185

Fonte: Elaborada pelo autor.

6 RESULTADOS

6.1 DEPÓSITOS SEM OTIMIZAÇÃO

Inicialmente, como demonstração de uma aplicação trivial da técnica de *Laser Cladding*, isto é, sem otimização, propôs-se revestir totalmente uma determinada área de uma amostra de aço 430 onde houvera manchas e gravações profundas previamente feitas a laser, além de degradações naturais da peça pela ação do tempo (Figura 6.1). Como atesta o resultado da detecção realizada pelo software, ilustrada na Figura 6.2, a região da superfície é problemática. Neste sentido, a proposta aqui foi recuperar totalmente esta área superficial (Figura 6.3) para outras aplicações. As Figuras 6.4, 6.5 e 6.6 apresentam respectivamente o mapa de trajetória em pixels, o processo de revestimento e o resultado final efetuado com o emprego de liga metálica Surfit™ 316L numa área depositada de aproximadamente 45x35mm (largura x altura). Detalhes da área depositada são ilustrados na Figura 6.7.

Figura 6.1 - Imagem de amostra de aço 430 captada pela câmera do sistema de deposição. Observa-se em sua superfície algumas áreas degradadas como manchas e gravações feitas a laser, além de oxidações.

Fonte: Elaborada pelo autor.

Figura 6.2 - Defeitos detectados na superfície da amostra pelo algoritmo do programa desenvolvido.
Fonte: Elaborada pelo autor.

Figura 6.3 - Imagem da amostra de aço 430 mostrando a região selecionada (quadrante em azul) via software desenvolvido para o projeto na qual o sistema realizará o depósito.
Fonte: Elaborada pelo autor.

Figura 6.4 - Mapa de trajetória em termos de pixels gerado pelo software (a deposição ocorrerá na área em preto).

Fonte: Elaborada pelo autor.

Figura 6.5 - Processo de deposição realizada pelo sistema na área selecionada da amostra de aço 430.

Fonte: Elaborada pelo autor.

Figura 6.6 - Resultado final do processo de deposição realizado na amostra de aço 430. Observa-se que a fina camada aplicada não foi suficiente para cobrir todos os defeitos presentes na superfície da amostra.

Fonte: Elaborada pelo autor.

Figura 6.7 – Imagem de microscopia óptica mostrando detalhes da área (região de um dos cantos) depositada na amostra de aço 430.

Fonte: Elaborada pelo autor.

Dando continuidade aos testes de recobrir integralmente uma determinada área foram empregados alguns pós metálicos normalmente utilizados em outros processos de deposição como a aspersão térmica, por exemplo. Os resultados, contudo, não foram satisfatórios tal como ilustrado nas Figuras 6.8 e 6.9 abaixo. A razão é devido às propriedades físicas desses materiais, como a granulometria: o tamanho grande ou irregular das pequenas esferas as impedem de serem completamente fundidas junto à superfície, ou então, no caso de se aumentar a potência do laser para contornar o problema, a vaporização tanto das partículas quanto dos materiais da superfície do substrato torna efeito, refletindo em uma deposição notadamente irregular, como pode ser facilmente observado nas imagens.

Figura 6.8 - Resultado da deposição de pó metálico Colmonoy 63 sobre a superfície de uma amostra de aço 304.
Fonte: Elaborada pelo autor.

Figura 6.9 - Resultado da deposição de pó metálico Durmat 60 AH sobre a superfície de uma amostra de aço SAE-8620.

Fonte: Elaborada pelo autor.

6.2 DEPÓSITOS EM REGIÕES COM PADRÕES DETECTADOS

6.2.1 Depósito em região com orifício circular

A Figura 6.10 apresenta a imagem de uma peça de aço SAE-1020 (porca tipo martelo "T") empregada para fixação de perfis modulares de alumínio. Objetiva-se, neste caso, tratar a superfície de contato desta porca com chapa onde a mesma será afixada. Em outras palavras, realizar um tratamento superficial para aumentar a resistência do material em relação à ferrugem e corrosão por meio do revestimento de um material adequado que neste caso é uma liga de aço inox (Surfit™ 316L).

Figura 6.10 - Imagem porca tipo T fabricada em aço carbono SAE-1020 (Dimensões aproximadas - Largura x Altura x Profundidade: 19x10x9mm).

Fonte: Elaborada pelo autor.

Da imagem acima, observa-se que a peça possui um furo central com rosca na face a ser revestida. O software de controle do sistema desenvolvido deve detectar esta forma padrão, evitando o depósito nessa região, importante em primeiro lugar por evitar danificar a rosca evidentemente e segundo por economizar o pó material de depósito e a energia consumida pelo laser.

A Figura 6.11 mostra a região selecionada da porca, isto é, sua face de contato, enquanto o resultado da detecção realizada pelo algoritmo do programa é visualizado na Figura 6.12 onde se observa a área total de interesse (em preto a área a ser depositada) e o círculo central em branco (área a ser “pulada”) na imagem alterada pelo software, caracterizando o mapa de trajetória o qual guiará a deposição. As Figuras 6.13, 6.14 e 6.15 mostram, respectivamente, o processo, o resultado final e detalhes da deposição efetuada.

Figura 6.11 - Região selecionada via software correspondendo a uma das faces da porca.
Fonte: Elaborada pelo autor.

Figura 6.12 – Mapa de trajetória gerado pelo sistema. Um objeto circular (identificado em branco) foi detectado pelo software desenvolvido ao pesquisar a área previamente selecionada da imagem (delimitada em preto).

Fonte: Elaborada pelo autor.

Figura 6.13 - Imagem mostrando o processo de deposição de pó metálico sobre a superfície de uma das faces da porca tipo T utilizada nos experimentos.

Fonte: Elaborada pelo autor.

Figura 6.14 - Resultado da deposição de liga de aço inox 316L sobre a face de uma porca tipo T. Área depositada aproximada: $1,3\text{cm}^2$. Camada depositada (altura): 0,1mm. Parâmetros utilizados pelo laser: CW, 20W.

Fonte: Elaborada pelo autor.

Figura 6.15 - Detalhes em imagem de microscopia da deposição de pó metálico sobre porca tipo T.
Fonte: Elaborada pelo autor.

6.2.2 Depósito em região com logotipo de empresa

Uma amostra de aço SAE-8620 cuja superfície apresentando polimento e gravação a laser de uma logomarca de empresa (Figura 6.16) foi submetida ao processo de revestimento. O sistema, por meio do algoritmo treinado, detectou tal padrão dentro dos limites da área selecionada para a tarefa na imagem ora tratada, tal como apresentado pelas Figuras 6.17, 6.18 e 6.19, gerando na sequência o mapa de trajetória em pixels representado na Figura 6.20. O resultado do procedimento de deposição é mostrado na Figura 6.21.

Figura 6.16 - Imagem amostra de aço SAE-8620 (Dimensões aproximadas - Largura x Altura x Profundidade: 80x42x9mm) apresentando uma gravação de logomarca em sua superfície.

Fonte: Elaborada pelo autor.

Figura 6.17 - Área selecionada da superfície da amostra de aço SAE-8620 apta para a análise realizada pelo software e passível de deposição.

Fonte: Elaborada pelo autor.

Figura 6.18 - Filtragem da Imagem da região selecionada. (a) Imagem normal; (b) Imagem tratada por filtro (NML).

Fonte: Elaborada pelo autor.

Figura 6.19 - Objeto detectado na imagem. Neste caso, uma logomarca que o algoritmo desenvolvido foi treinado para reconhecer em imagens.

Fonte: Elaborada pelo autor.

Figura 6.20 - Mapa de trajetória gerado pelo sistema. A área em branco refere-se ao logotipo identificado pelo software desenvolvido ao pesquisar a área previamente selecionada da imagem (delimitada em preto).

Fonte: Elaborada pelo autor.

Figura 6.21 - Resultado da deposição de liga de aço inox 316L em pó sobre a face de uma amostra de aço SAE-8620. Área depositada total (aproximadamente): $13,5\text{cm}^2$. Camada depositada (altura): 0,1mm. Parâmetros utilizados pelo laser: CW, 20W.

Fonte: Elaborada pelo autor.

6.2.3 Depósito em região com *QR Code*

Para finalizar a demonstração da técnica desenvolvida em aplicações cujas superfícies apresentam determinados objetos padrões, revestiu-se uma área da superfície de uma mostra de chapa de aço 316L contendo a gravação de um tipo de código de barras bidimensional conhecido como *QR Code* (Figura 6.22). O sistema procedeu tal como nos dois últimos exemplos apresentados anteriormente, isto é, detectou o objeto e realizou a deposição em toda a área selecionada, à exceção da região abrangida pelo ente detectado, conforme os passos realizados, os quais podem ser apreciados nas Figuras 6.23, 6.24, 6.25 e 6.26.

Figura 6.22 - Imagem captada pela câmera do sistema referente à amostra de chapa de aço 316L (Dimensões aproximadas - Largura x Altura x Profundidade: 191x100x4mm) apresentando uma gravação de *QR Code* em sua superfície.

Fonte: Elaborada pelo autor.

Figura 6.23 - Área seleccionada da superfície da amostra de aço 316L apta para análise do software e passível de deposição.

Fonte: Elaborada pelo autor.

Figura 6.24 – *QR Code* detectado na imagem captada pela câmera do sistema.

Fonte: Elaborada pelo autor.

Figura 6.25 - Mapa de trajetória gerado pelo sistema. A área abrangendo o *QR Code* (identificado em branco) será poupado do processo de revestimento ao contrário do restante da área pesquisada pelo software (em preto).

Fonte: Elaborada pelo autor.

Figura 6.26 - Resultado da deposição de liga de aço inox sobre uma área em torno de um *QR Code* presente na superfície de uma chapa de aço 316L. Área depositada aproximada: $11,8\text{cm}^2$. Camada depositada (altura): 0,15mm. Parâmetros utilizados pelo laser: CW, 25W.

Fonte: Elaborada pelo autor.

6.3 RECONSTRUÇÃO DE UM OBJETO DETECTADO

Em um outro tipo de teste colocou-se o sistema para identificar um padrão, neste caso um objeto circular, e depositar uma série de camadas sucessivas de material metálico em pó neste local, erigindo a construção de um objeto cilíndrico. A ideia nesta abordagem é reconstruir um objeto 3D que fora danificado: um pino de suporte ou de encaixe de uma carcaça fabricada em alumínio referente a um determinado dispositivo eletrônico (Figura 6.27).

Figura 6.27 - Carcaça de um dispositivo eletrônico fabricado em alumínio (Dimensões aproximadas - Largura x Altura x Profundidade: 68x40x17mm). Em vermelho: local a ser reconstruído via depósito.

Fonte: Elaborada pelo autor.

Para a tarefa, o sistema capturou a imagem da peça, detectando, em uma área previamente selecionada, o mesmo padrão circular do orifício tratado anteriormente neste projeto (são similares, à exceção do contraste da região interior que é corrigido via filtros, tornando o software apto a reconhecer ambos os padrões), gerando o respectivo mapa de trajetória (Figura 6.28). A diferença, porém, é que agora, via interface do software, o usuário opta por “depositar nas áreas detectadas”, ou seja, o sistema direciona a deposição do pó metálico exatamente à área detectada referente ao objeto. A Figura 6.29 apresenta o resultado final do processo de reconstrução que utilizou alumínio em pó, permitindo a fabricação de um objeto com cerca de 4,5mm de altura aproximadamente.

Figura 6.28 - Área selecionada da superfície da carcaça metálica (imagem superior) apta à análise pelo software. Este detectou um padrão circular na região gerando o mapa de trajetória (imagem inferior).

Fonte: Elaborada pelo autor.

Figura 6.29 - Resultado do depósito de sucessivas camadas de pó de alumínio sobre uma região circular, reconhecida pelo sistema de detecção desenvolvido, presente na superfície de uma carcaça metálica, caracterizando a reconstrução de uma parte danificada (Dimensões aproximadas do objeto construído - Diâmetro x Altura: 3,5x4,5mm). Parâmetros utilizados pelo laser: Pulsado, 30W (o alumínio possui a característica de refletir mais a luz do laser utilizado quando comparado ao aço; por essa razão mais energia deve ser fornecida ao processo e isso se obtém utilizando o laser no modo de pulsos os quais possuem alta energia).

Fonte: Elaborada pelo autor.

Observa-se no resultado acima que há uma certa porosidade e/ou irregularidade na superfície depositada. Isto se deve ao fato que o pó de alumínio utilizado possuir granularidade bem pequena ($< 5\mu\text{m}$) e com tendência a compactar-se com muita facilidade dificultando o processo de injeção (ocorrência de variação da taxa de injeção de pó durante o processo), cujo projeto não fora concebido para operar em uma faixa ampla em relação a tal característica. Contudo, o resultado alcançado prova a versatilidade do sistema, isto é, este pode operar além da simples tarefa de revestir superfícies.

6.4 DEPÓSITO EM REGIÕES COM DEFEITOS DETECTADOS

Como último tipo de teste submetido ao sistema desenvolvido, fora-lhe incumbido detectar um defeito, neste caso em especial, algo como uma ranhura, depressão ou cavidade e realizar a devida deposição nessa região, ou seja, recuperar essa área degradada.

Selecionou-se, via software criado, três regiões cujo interior continha pronunciadas ranhuras (dimensões aproximadas: 19 a 35mm de comprimento; 3mm de largura máxima; 1,5mm de profundidade máxima) presentes na superfície de uma peça de aço inox 304, conforme observado na Figura 6.30. A imagem das áreas selecionadas foi tratada pelo sistema e a deposição realizada com pó metálico Surfit™ 316L dentro dos limites das regiões com fendas detectadas pelo algoritmo de reconhecimento de defeitos implementados (Figuras 6.31, 6.32 e 6.33), sendo o processo, resultado e detalhes visualizados respectivamente nas Figuras 6.34, 6.35 e 6.36.

Figura 6.30 - Imagem captada pela câmera do sistema referente a uma chapa de aço 304 apresentando em sua superfície três pronunciadas fendas (Dimensões aproximadas - Largura x Altura x Profundidade: 160x85x5mm).

Fonte: Elaborada pelo autor.

Figura 6.31 - Área selecionada da superfície de chapa de aço 304 apta para análise do software e passível de deposição. Observa-se a presença de três ranhuras dentro destes limites.

Fonte: Elaborada pelo autor.

Figura 6.32 - Imagem da região selecionada da superfície de chapa de aço 304 tratada pelo sistema através de filtros (à esquerda). Defeitos (ranhuras) detectados pelo software (à direita).

Fonte: Elaborada pelo autor.

Figura 6.33 - Mapa de trajetória gerado pelo sistema. A área abrangendo as ranhuras (identificado em branco) será o alvo do processo de revestimento em detrimento do restante da área selecionada (em preto).

Fonte: Elaborada pelo autor.

Figura 6.34 - Processo de deposição de pó metálico sobre as fendas detectadas pelo software na superfície de uma chapa de aço 304. O tempo total da operação foi de aproximadamente seis horas.

Fonte: Elaborada pelo autor.

Figura 6.35 - Resultado do depósito de liga de aço inox em pó sobre as fendas detectadas pelo software na superfície de uma chapa de aço 304. Área total depositada (aproximadamente): $3,5\text{cm}^2$. Parâmetros utilizados pelo laser: CW, 20W.

Fonte: Elaborada pelo autor.

Figura 6.36 - Detalhes em imagem de microscopia da deposição de pó metálico sobre uma região de uma das fendas preenchidas no processo (uma das extremidades).

Fonte: Elaborada pelo autor.

Interessante observar a economia de recursos (pó, tempo, energia e gás de transporte, por exemplo) representada por este processo otimizado desenvolvido: caso toda a área selecionada fosse depositada, ter-se-ia um total de 36cm^2 de cobertura; em contrapartida, ao focar o processo nas áreas específicas de interesse, a área depositada foi reduzida de forma expressiva em praticamente 10 vezes.

Ressalta-se que este processo de preenchimento de cavidades (descrito acima) ou a construção de partes (como, por exemplo, o realizado na fabricação do objeto cilíndrico anteriormente demonstrado neste trabalho) é complexo e lento (repetição de uma série de camadas) sendo o controle de parâmetros e outras variáveis do sistema extremamente importantes. A utilização do sensor de distância a laser de precisão como elemento central da malha de controle em malha fechada mostrou-se crucial neste sentido.

7 CONCLUSÕES

O objetivo principal deste projeto de mestrado aqui reportado foi desenvolver um sistema de bancada apto a realizar a deposição controladamente inteligente de materiais metálicos em forma pó sobre superfícies metálicas mediante a fusão à alta temperatura despendida pelo foco de um raio laser incidente nessas superfícies com o intuito de tratar ou recuperar tais estruturas. Neste sentido, foi implementada, na prática, uma estrutura mecânica automatizada dotada de sistema de pulverização de pós metálicos e de controles embarcados baseados em um conjunto de algoritmos de visão computacional e aprendizagem de máquina, além de todo o hardware e software necessários para guiar o processo de deposição. Portanto, a meta base ou principal do projeto foi plenamente atingida.

Pelos testes realizados, atestou-se que há muitos parâmetros envolvidos no processo de deposição *Laser Cladding* e estes influenciam de maneira direta no resultado final desta técnica de manufatura aditiva, fato condizente com a literatura nessa área. Exemplos disto, são os resultados negativos produzidos pela utilização de insumos que se mostraram inadequados, mais especificamente pós metálicos não explicitamente indicados para o referido método de deposição, como ficou evidenciado em alguns dos experimentos.

O processo de deposição dos materiais metálicos nas superfícies trabalhadas e principalmente nos testes com preenchimento de volumes (recobrimento de fendas e construção de objetos 3D) se mostrou relativamente lento como se esperava, haja vista a reduzida escala em que o protótipo fora concebido, ou seja, direcionado mais à prova do conceito proposto que às pretensões em termos de escala industrial ou profissional.

Guardados os devidos aprimoramentos e adaptações necessárias, é possível, a partir do protótipo desenvolvido e da performance por este apresentado, extrapolar o modelo construído em direção a constituição de um sistema funcional de impressão 3D de materiais em pó, além dos metálicos, aproveitando-se da energia fornecida pelo laser e do sistema de visão inteligente elaborado. Tal sistema permitiria, ao contrário das impressoras usuais que necessitam de modelos CAD pré-definidos do objeto a ser construído, estabelecer a área ou o volume a ser fabricado baseado no reconhecimento de imagens e aprendizado de máquina em tempo real. Esta última condição é quase que imperativa ante às exigentes demandas mercadológicas atuais, fortemente voltadas às customizações aliadas à escalabilidade do produto ou processo.

Os resultados apresentados mediante a série de testes realizados com as detecções de objetos padrões elencados para o projeto demonstram a prova de conceito do princípio proposto e a consequente viabilidade de desenvolvimento de outros tipos de sistemas empregando a abordagem adotada. Com efeito, o método aqui pesquisado, baseado no estado da arte em termos de inteligência artificial, abre novas possibilidades ao utilizar um processo cujo consumo de material e energia são minimizados, fatores importantíssimos para um futuro sustentável e energeticamente eficiente, algo que vai ao encontro do preconizado pela proeminente indústria 4.0 que foca na agregação de valor e fluidez dos processos com o mínimo possível de desperdício na cadeia produtiva.

Em vista do exposto nos parágrafos anteriores, propõe-se, como linha de continuidade a esta pesquisa, a adequação do equipamento à novos materiais, além do aprimoramento dos algoritmos de detecção desenvolvidos, no sentido de unificá-los e expandi-los para um maior número de objetos detectáveis em tempo real. Para tanto, a utilização do conjunto de dados armazenados durante o processo em todos os testes realizados ou a realizar-se é fundamental, exigindo, consequentemente, estudos elaborados para tratar e analisar corretamente esses dados.

Destaca-se, entre outros pontos positivos alcançados com este trabalho, o forte caráter multidisciplinar científico, tecnológico e inovador envolvido neste projeto. Agregou-se, sob essa ótica, capacitação e conhecimentos técnicos valiosos a todos os membros envolvidos direta ou indiretamente no transcurso da pesquisa, além de promover a salutar aproximação entre o meio acadêmico e a indústria junto a tais tecnologias consideradas disruptivas e cujo know-how se apresenta como contribuição vital para o desenvolvimento do país.

REFERÊNCIAS*

- 1 DUTTA MAJUMDAR, J.; MANNA, I. Laser processing of materials. **Sadhana**, v. 28, n. 34, p. 495-562, 2003.
- 2 TOYSERKANI, E.; KHAJEPOUR, A.; CORBIN, S. **Laser cladding**. Florida: CRC Press LLC, 2000.
- 3 GU, D. **Laser additive manufacturing of high-performance materials**. Berlin Heidelberg: Springer-Verlag, 2015.
- 4 PINKERTON, A. J. Lasers in additive manufacturing. **Optics & Laser Technology**, v. 78, Part A, p. 25-32, 2016.
- 5 SINGH, S.; RAMAKRISHNA, S. Material issues in additive manufacturing: a review. **Journal of Manufacturing Processes**, v. 25, p. 185-200, 2017. doi: 10.1016/j.jmapro.2016.11.006.
- 6 SCHMIDT, M. *et al.* Laser based additive manufacturing in industry and academia. **CIRP Annals**, v. 66, n. 2, p. 561-583, 2017.
- 7 TORRES, J. M. S. P. **Melhoramento e automatização de um sistema de revestimento com laser**. 2015. 99 p. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Ciências e Tecnologia, Universidade Nova, Lisboa, 2015.
- 8 INTERREG SUDOE - ADDI SPACE. State of the art of Additive Manufacturing Technologies: technologies, trends, opportunities, challenges and applications to the aerospace sector. 2017. Disponível em: http://www.addispace.eu/gestor/recursos/uploads/imagenes/noticias/INFORME/State_of_the_art_MAM-ENGLISH_low.pdf. Acesso em: 25 fev. 2019.
- 9 CASALINO, G. Computational intelligence for smart laser materials processing. **Optics & Laser Technology**, v. 100, p. 165-175, 2018. doi: 10.1016/j.optlastec.2017.10.011.
- 10 VEIT, D.R. **Impactos da manufatura aditiva nos sistemas produtivos e suas repercussões nos critérios competitivos**. 2018. Tese (Doutorado) - Universidade do Vale do Rio dos Sinos, UNISINOS, São Leopoldo, 2018.
- 11 WONG, K.V.; HERNANDEZ, A. A review of additive manufacturing. **ISRN Mechanical Engineering**, v. 2012, 2012. doi: 10.5402/2012/208760.
- 12 FRAZIER, W. E. Metal additive manufacturing: a review. **Journal of Materials Engineering and Performance**, v. 23, n. 6, p. 1917-1928, 2014.

* De acordo com a Associação Brasileira de Normas Técnicas NBR 6023:2018.

-
- 13 STEREOGRAPHY APPARATUS. **Stereolithography apparatus schematic**. 2008. Disponível em: https://commons.wikimedia.org/wiki/File:Stereolithography_apparatus.jpg. Acesso em: 26 fev. 2019.
- 14 WANG, X. *et al.* 3D printing of polymer matrix composites: a review and prospective. **Composites Part B: engineering**, v. 110, p. 442-458, 2017. doi: 10.1016/j.compositesb.2016.11.034.
- 15 NGO, T.D. *et al.* Additive manufacturing (3D printing): a review of materials, methods, applications and challenges. **Composites Part B: engineering**, v. 143, p. 172-196, 2018. doi: 10.1016/j.compositesb.2018.02.012.
- 16 SELECTIVE LASER SINTERING. **SLS system schematic**. 2019. Disponível em: https://commons.wikimedia.org/wiki/File:Selective_Laser_Sintering.svg. Acesso em: 26 fev. 2019.
- 17 MANOGHARAN, G. *et al.* AIMS - a metal additive-hybrid manufacturing system: system architecture and attributes. **Procedia Manufacturing**, v. 1, p. 273-286, 2015. doi: 10.1016/j.promfg.2015.09.021.
- 18 KAIERLE, S. *et al.* Review on laser deposition welding: from micro to macro. **Physics Procedia**, v. 39, p. 336-345, 2012. doi: 10.1016/j.phpro.2012.10.046.
- 19 ZHONG, M.; LIU, W. Laser surface cladding: the state of the art and challenges. **Proceedings of the Institution of Mechanical Engineers Part C: journal of mechanical engineering science**, v. 224, n. 5, p. 1041-1060, 2010.
- 20 THOMPSON, S. M. *et al.* An overview of direct laser deposition for additive manufacturing: part I: transport phenomena, modeling and diagnostics. **Additive Manufacturing**, v. 8, p. 36-62, 2015. doi: 10.1016/j.addma.2015.07.001.
- 21 BATUT, B.L. *et al.* Analytical and numerical temperature prediction in direct metal deposition of Ti6Al4V. **Journal of Manufacturing and Materials Processing**, 2017. doi: 10.3390/jmmp1010003.
- 22 BORGES, B. *et al.* Imperfections in laser cladding with powder and wire fillers. **The International Journal of Advanced Manufacturing Technology**; v. 50, p. 175-183, 2010. doi: 10.1007/s00170-009-2480-2.
- 23 SOUTO, H. I. M. **Laser cladding: sua aplicação à deposição de revestimentos em lâminas de destruidores de madeira**. 2010. Dissertação (Mestrado) - Faculdade de Engenharia, Universidade do Porto, Porto, 2010.
- 24 GEDDA, H. **Laser surface cladding - a literature survey**. Luleå: Luleå University of Technology, 2000. p.1402-1536. Technical report.
- 25 HOFMAN, J.T. **Development of an observation and control system for industrial laser cladding**. 2009. Ph. D. Thesis (Technology) - Faculty of Engineering Technology, University of Twente, Enschede, 2009.

- 26 HERALIC, A. **Monitoring and control of robotized laser metal-wire deposition**. 2012. Ph. D. Thesis (Philosophy) - Department of Signals and Systems, Chalmers University of Technology, Göteborg, 2012.
- 27 TOYSERKANI, E; KHAJEPOUR, A. A mechatronics approach to laser powder deposition process. **Mechatronics**, v. 16, p. 631-641, 2006. doi: 10.1016/j.mechatronics.2006.05.002.
- 28 TABRIZIPOUR, M.I.; TOYSERKANI, E. An image-based feature tracking algorithm for real-time measurement of clad height. **Machine Vision and Applications**, v. 18, p. 343-354, 2007. doi: 10.1007/s00138-006-0066-7.
- 29 BOISSELIER, D; SANKARÉ, S.; ENGEL, T. Improvement of the laser direct metal deposition process in 5-axis configuration. **Physics Procedia**, v. 56, p. 239-249, 2014. doi: 10.1016/j.phpro.2014.08.168.
- 30 ZEINALI, M; KHAJEPOUR, A. Development of an adaptive fuzzy logic-based inverse dynamic model for laser cladding process. **Engineering Applications of Artificial Intelligence**, v. 23, p. 1408-1419, 2010. doi: 10.1016/j.engappai.2009.11.006.
- 31 TORIMS, T. **The application of laser cladding to mechanical component repair, renovation and regeneration**. 2013. Disponível em: https://www.daaam.info/Downloads/Pdfs/science_books_pdfs/2013/Sc_Book_2013-032.pdf. Acesso em: 23 jan. 2018.
- 32 NOWOTNY, S. *et al.* Laser beam build-up welding: precision in repair, surface cladding, and direct 3D metal deposition. **Journal of Thermal Spray Technology**, v. 16, p. 344-348, 2007. doi: 10.1007/s11666-007-9028-5.
- 33 GIBSON, I; ROSEN, D. W.; STUCKER, B. **Additive manufacturing technologies: rapid prototyping to direct digital manufacturing**. New York: Springer Science Business Media, 2010.
- 34 LUDOVICO, A. D.; ANGELASTRO, A.; CAMPANELLI, S. L. **Experimental analysis of the direct laser metal deposition process**. 2010. Disponível em: <http://cdn.intechweb.org/pdfs/12286.pdf>. Acesso em: 23 jan. 2018.
- 35 GONG, X.; ANDERSON, CHOU, K. Review on powder-based electron beam additive manufacturing technology. **Manufacturing Review**, v. 1, p. 12. 2014. doi: 10.1051/mfreview/2014001.
- 36 SLOTWINSKI, J. A. *et al.* Characterization of metal powders used for additive manufacturing. **Journal of Research of the National Institute of Standards and Technology**, v. 119, p. 460-493, 2014. doi: 10.6028/jres.119.018.
- 37 LASCHKOW, A. *et al.* **Wire and powder laser cladding of Inconel® 625**. 2017. Disponível em: <https://pdfs.semanticscholar.org/6d7f/1bf641b9e39081cff545fa68750ad9bc871b.pdf>. Acesso em: 23 jan. 2019.

- 38 MORVILLE, S. *et al.* **Numerical modeling of powder flow during coaxial laser direct metal deposition - Comparison between Ti-6Al-4V Alloy and Stainless Steel 316L.** 2012. Disponível em: https://www.comsol.eu/paper/download/151903/carin_paper.pdf. Acesso em: 23 jan. 2019.
- 39 TANIGAWA, D. *et al.* **Influence of particle size on heat affected zone in laser cladding.** 2015. Disponível em: https://www.wlt.de/lim/Proceedings2015/Stick/PDF/Contribution233_final.pdf. Acesso em: 23 jan. 2019.
- 40 PONCHE, R. *et al.* A novel methodology of design for additive manufacturing applied to additive laser manufacturing process. **Robotics and Computer-Integrated Manufacturing**, v. 30, p. 389-398, 2014. doi: 10.1016/j.rcim.2013.12.001.
- 41 BERUMEN, S. *et al.* Quality control of laser and powder bed-based additive manufacturing (AM) technologies. **Physics Procedia**, v. 5, p. 617-622, 2010. doi: 10.1016/j.phpro.2010.08.089.
- 42 BI, G. *et al.* Development and qualification of a novel laser-cladding head with integrated sensors. **International Journal of Machine Tools & Manufacture**, v. 47, p. 555-561, 2007. doi: 10.1016/j.ijmachtools.2006.05.010.
- 43 KLOCKE, F. *et al.* Scanner-based laser cladding. **Physics Procedia**, v. 39, p. 346-353, 2012. doi: 10.1016/j.phpro.2012.10.047.
- 44 PURTONEN, T.; KALLIOSAARI, A.; SALMINEN, A. Monitoring and adaptive control of laser processes. **Physics Procedia**, v. 56, p. 1218-1231, 2014. doi: 10.1016/j.phpro.2014.08.038.
- 45 BAUFELD, B.; BIEST, O. V.; GAULT, R. Additive manufacturing of Ti-6Al-4V components by shaped metal deposition: microstructure and mechanical properties. **Materials and Design**, v. 31, p. 106-111, 2010. doi: 10.1016/j.matdes.2009.11.032.
- 46 MAZUMDER, J. *et al.* Closed loop direct metal deposition: art to part. **Optics and Lasers in Engineering**, v. 34, p. 397-414, 2000. doi: 10.1016/S0143-8166(00)00072-5.
- 47 HU, D. *et al.* **Closed loop control of 3D laser cladding based on infrared sensing.** 2001. Disponível em: <https://pdfs.semanticscholar.org/7d33/0473f800ee326c0f61bfbb1293438733e799.pdf>. Acesso em: 23 jan. 2019.
- 48 MEIJER, J. Laser beam machining (LBM), state of the art and new opportunities. **Journal of Materials Processing Technology**, v. 149, p. 2-17, 2004. doi: 10.1016/j.jmatprotec.2004.02.003.
- 49 SHAMSAEI, N. *et al.* An overview of direct laser deposition for additive manufacturing - part II: mechanical behavior, process parameter optimization and control. **Additive Manufacturing**, v. 8, p. 12-35, 2015. doi: 10.1016/j.addma.2015.07.002.

- 50 QILIN, D. *et al.* Measurement of the molten pool image during laser cladding process. *In: INTERNATIONAL CONFERENCE ON MECHATRONICS, ELECTRONIC, INDUSTRIAL AND CONTROL ENGINEERING, MEIG-14*, 2014, Shenyang, China.. **Proceedings** [...]. S.l.: Atlantic Press, 2014. doi: 10.2991/meic-14.2014.141.
- 51 MAZUMDER, J. Design for metallic additive manufacturing machine with capability for certify as you build. **Procedia CIRP**, v. 36, p. 187-192, 2015. doi: 10.1016/j.procir.2015.01.009.
- 52 VALLEJO, D.D; ASHKENASI, D.; EICHLER, H.J. Monitoring of focus position during laser processing based on plasma emission. **Physics Procedia**, v. 41, p. 911-918, 2013. doi: 10.1016/j.phpro.2013.03.166.
- 53 WEISHEIT, A. *et al.* Powder injection: the key to reconditioning and generating components using laser cladding. *INTERNATIONAL CONGRESS ON ADVANCED MATERIALS, THEIR PROCESSES AND APPLICATIONS*, 2001, Werkstoffwoche, Muchen. **Proceedings** [...]. Frankfurt: Werkstoffwoche- Patnerschaft, 2002.
- 54 LAMIKIZ, A. *et al.* Current designs of coaxial nozzles for laser cladding. **Recent Patents on Mechanical Engineering**, v. 4, p. 29-36, 2011. doi: 10.2174/2212797611104010029
- 55 FRAUNHOFER-INSTITUT FÜR LASERTECHNIK ILT. **System engineering for powder-based laser cladding**. 2013. Disponível em: http://www.ilt.fraunhofer.de/en/publication-and-press/brochures/brochure_System_Engineering_for_Powder-Based_Laser_Cladding.html. Acesso em: 02 mar. 2018.
- 56 GAO, W. *et al.* The status, challenges, and future of additive manufacturing in engineering. **Computer-Aided Design**, v. 69, p. 65-89, 2015. doi: 10.1016/j.cad.2015.04.001.
- 57 TORRES, J. M .S. P.; MORGADO, T. L. M.; NAVAS, H. V. G. Innovative automation equipment of laser cladding. *In: INTERNATIONAL CONFERENCE ON SYSTEMATIC INNOVATION*, 6th, 2015, Hong Kong. **Proceedings** [...]. Taiwan: The Society of Systematic Innovation, 2015. doi: 10.13140/RG.2.1.3675.4002.
- 58 WANG, D. *et al.* Study on deposition rate and laser energy efficiency of laser-induction hybrid cladding. **Optics & Laser Technology**, v. 77, p. 16-22, 2016. doi: 10.1016/j.optlastec.2015.08.019.
- 59 WANG, D. *et al.* Microstructure and properties of the interface area in the laser clad Ni based coatings on the 1Cr10Mo1NiWVNbN steel. **Metals**, v. 7, n. 175, 2017. doi:10.3390/met7050175.
- 60 HÖGANÄS AB. **Thermal surfacing powder choice with ease**. 2014. Disponível em: https://www.hoganas.com/globalassets/media/sharepoint-documents/BrochuresanddatasheetsAllDocuments/Powder_choice_with_ease.pdf. Acesso em: 05 mar. 2019.

-
- 61 CHAUDHARI, P. S.; PATEL, D. M.; JUNEJA, J. L. Artificial intelligence apply for prediction of laser cutting process - a review. **International Journal of Engineering Research and Applications (IJERA)**, v. 2, n. 4, p. 1025-1028, 2012.
- 62 CALATORU, V.; BALAZINSKI, M.; RIVETTE, M. **Investigation into potential use of artificial intelligence techniques in piloting additive manufacturing systems for metallic materials.** 2014. Disponível em: https://cmmi.tuiasi.ro/wp-content/uploads/buletin/2014%20fasc%201/L4%20CM%201_2014.pdf. Acesso em: 23 jan. 2019.
- 63 CAIAZZO, F.; CAGGIANO, A. Laser direct metal deposition of 2024 al alloy: trace geometry prediction via machine learning. **Materials**, v. 11, n. 444, 2018. doi: 10.3390/ma11030444.
- 64 MONDAL, S. *et al.* Process optimization for laser cladding operation of alloy steel using genetic algorithm and artificial neural network. **International Journal of Computational Engineering Research**, v. 2, n. 1, p. 18-24, 2012.
- 65 FERNANDES, J.G.L. *et al.* Inteligência artificial: uma visão geral. **Revista Eletrônica Engenharia Estudos e Debates**, v. 1, 11p., 2018.
- 66 ANTONELLO, R. **Introdução a visão computacional com Python e OpenCV**, 2018. Disponível em: <https://cv.antonello.com.br/visao-computacional/>. Acesso em: 10 mar. 2019.
- 67 GRABNER, H.; BELEZNAI, C. History of computer vision. **OCG Journal - das Magazin der Österreichischen Computer Gesellschaft**, v. 3, n. 33, p. 28-29, 2008.
- 68 NEVES, L.A.P.; VIEIRA NETO, H.; GONZAGA, A. **Avanços em visão computacional**. Curitiba: Omnipax Editora, 2012.
- 69 NEMATOLLAHI, M.A.; SHAHBAZI, S.; NABIAN, N. **Computer vision and audition in urban analysis using the remorph framework (studies in systems, decision and control)**. Singapore: Springer Nature, 2018.
- 70 SZELISKI, R. **Computer vision: algorithms and applications**. New York: Springer Verlag, 2010.
- 71 BRADSKI, G.; KAEHLER, A. **Learning openCV**. Gravestien: O'Reilly Media, Inc., 2008.
- 72 HUANG, T.S. **Computer vision: evolution and promise**. Disponível em: <https://cds.cern.ch/record/400313/files/p21.pdf>. Acesso em: 17 marco, 2020.
- 73 LEARNED-MILLER, E.G. **Introduction to computer vision**, New York: Springer Verlag, 2011.
- 74 KRISHNA, R. **Computer vision: foundations and applications**. Stanford University, 2017.
- 75 GONZALEZ, R.C.; WOODS, R.E., **Digital image processing**. 3th. ed. New York: Pearson-Prentice-Hall, 2008.

-
- 76 DAVIES, E.R. **Computer vision: principles, algorithms, applications, learning**. 5th. ed. New York: Elsevier Inc., 2018.
- 77 MARSHALL, A.D.; MARTIN, R.R. **Computer vision, models, and inspection**. Singapore: World Scientific Publishing, 1992. (Series in Robotics and Automated Systems. v. 4).
- 78 GONZALEZ, R.C.; WOODS, R.E. **Processamento de imagens digitais**. New York: Ed. Blucher, 2000.
- 79 RUSS, J.C. **The image processing handbook**. 5th. ed. New York: CRC Press LLC, 2002.
- 80 ADDICAM, S.; MALIK, S.; TIAN, P. **Building intelligent systems: utilizing computer vision, data mining, and machine learning**. *s.l.*: Intel Press, 2012.
- 81 SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing, analysis, and machine vision**. 3th. ed. *s.l.*: Thomson, 2008.
- 82 DUDA, R.O.; HART, P.E.; STORK, D.G. **Pattern classification**. 2nd. ed. New York: Wiley - Interscience, 2001.
- 83 VIOLA, P.; JONES, M. Rapid object detection using a boosted cascade of simple features. **IEEE Conference on Computer Vision and Pattern Recognition**, p. 511-518, 2001.
- 84 KUNG, S.Y. **Kernel methods and machine learning**, Cambridge University Press, 2014.
- 85 MARSLAND, S. **Machine learning: an algorithmic perspective**. New York: CRC Press, 2009.
- 86 SHALEV-SHWARTZ, S.; BEN-DAVID, S. **Understanding machine learning - from theory to algorithms**. Cambridge: Cambridge University Press, 2014.
- 87 MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of machine learning**. New York: The MIT Press, 2012.
- 88 AWAD, M.; KHANNA, R. **Efficient learning machines - theories, concepts, and applications for engineers and system designers**. *s.l.*: Apress, 2015.
- 89 ALPAYDIN, E. **Introduction to machine learning**. 2nd. ed.; The MIT Press, 2010.
- 90 DOMINGOS, P. A few useful things to know about machine learning; **Communications of the ACM**, v. 55, p. 78-87, 2012. doi: 10.1145/2347736.2347755.
- 91 BISHOP, C.M. **Pattern recognition and machine learning**. New York: Springer, 2007.
- 92 VOULODIMOS, A. *et al.* Deep learning for computer vision: a brief review. **Computational Intelligence and Neuroscience**, p. 1-13, 2018. doi: 10.1155/2018/7068349.

-
- 93 LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. Convolutional Networks and Applications in Vision; **International Symposium on Circuits and Systems**, 2010.
- 94 BOSER, B.E., GUYON, I.M.; VAPNIK, V.N. A training algorithm for optimal margin classifiers. *In: ANNUAL WORKSHOP ON COMPUTATIONAL LEARNING THEORY, COLT 92*, 5th, 1992, Pennsylvania, **Proceedings[...]** Pittsburg: 1992. p. 144-152.
- 95 DOCS.OPENCV.ORG. **Understanding SVM**. Disponível em: https://docs.opencv.org/3.0.0/d4/db1/tutorial_py_svm_basics.html. Acesso em: 08 mai. 2019.
- 96 OWEISS, K.G. **Statistical signal processing for neuroscience and neurotechnology**. New York: Academic Press, 2010.
- 97 LORENA, A.C.; CARVALHO, A.C.P.L.F. **Introdução às máquinas de vetores suporte**. Relatórios Técnicos do ICMC - n°192, 2003.
- 98 BARBER, D. **Bayesian reasoning and machine learning**. Cambridge: Cambridge University Press, 2012.
- 99 SILVA, I.N. *et al.* **Artificial neural networks - a practical course**. New York: Springer, 2017.
- 100 MCCULLOCH, W.S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943. doi: 10.2307/2268029.
- 101 PRIETO, A. *et al.* Neural networks: an overview of early research, current frameworks and new challenges. **Neurocomputing**, v. 214, p. 242-268, 2016. doi: 10.1016/j.neucom.2016.06.014.
- 102 GUO, Y. *et al.* Deep learning for visual understanding: a review. **Neurocomputing**, v. 187, p. 27-48, 2016. doi: 10.1016/j.neucom.2015.09.116.
- 103 PONTI, M.A.; COSTA, G.B.P. Como funciona o Deep Learning. *In: TÓPICOS EM GERENCIAMENTO DE DADOS E INFORMAÇÕES*, 2017. Sao Carlos: ICMC, 2017. cap.3.
- 104 FINOCCHIO, M.A.F. **Noções de redes neurais artificiais**. Curitiba: UTFPR - Universidade Tecnológica Federal do Paraná, 2014. Disponível em: <http://paginapessoal.utfpr.edu.br/mafinocchio/labsi-laboratorio-de-seguranca-e-iluminacao/redes-neurais-artificiais/>. Acesso em: 08 jul. 2019.
- 105 SCHMIDHUBER, J. Deep learning in neural networks: an overview. **Neural Networks**, v. 61, p. 85-117, 2015. doi: 10.1016/j.neunet.2014.09.003.
- 106 LIU, W. *et al.* A survey of deep neural network architectures and their applications., **Neurocomputing**, v. 234, p. 11-26, 2017. doi: 10.1016/j.neucom.2016.12.038.
- 107 UZAN, H. *et al.* Biological learning curves outperform existing ones in artificial intelligence algorithms. **Scientific Reports**, v. 9, n. 11558, 2019.

- 108 EBERMAM, E.; KROHLING, R.A. Uma introdução compreensiva das redes neurais convolucionais: um estudo de caso para reconhecimento de caracteres alfabéticos. **Revista de Sistemas de Informação da FSMA**, n. 22, p. 49-59, 2018.
- 109 HAYKIN, S. **Redes neurais: princípios e prática**; 2.ed. S.I. Bookman, 2001.
- 110 BUSSON, A.J.G. *et al.* Desenvolvendo modelos de deep learning para aplicações multimídia no Tensorflow. In: SIMPÓSIO BRASILEIRO DE SISTEMAS MULTIMÍDIA E WEB E MINICURSOS, 24,2018., Salvador. **Anais[...]** Salvador: Sociedade Brasileira de Computacao, 2018.cap.3.
- 111 HUBEL, D.H.; WIESEL, T.N. Receptive fields, binocular interaction, and functional architecture in the cat's visual cortex. **The Journal of Physiology**, v. 160, p. 106-154, 1962. doi: 10.1113/jphysiol.1962.sp006837.
- 112 HUBEL, D.H.; WIESEL, T.N. Receptive fields and functional architecture of monkey striate cortex. **The Journal of Physiology**, v. 195, p. 215-243, 1968. doi: 10.1113/jphysiol.1968.sp008455.
- 113 FUKUSHIMA, K.; MIYAKE, S. Neocognitron: a self-organizing neural network model for a mechanism of visual pattern recognition. **Lecture Notes in Biomathematics**, v. 45, Springer, 1982. doi: 10.1007/978-3-642-46466-9_18.
- 114 GU, J. *et al.* Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354-377, 2018. doi: 10.1016/j.patcog.2017.10.013.
- 115 KIM, J.Y.; CHO, S.B. Exploiting deep convolutional neural networks for a neural-based learning classifier system., **Neurocomputing**, v. 354, p. 61-70, 2019. doi: 10.1016/j.neucom.2018.05.137.
- 116 KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G.E. Imagenet classification with deep convolutional neural networks. **Advances in neural information processing systems**, p. 1097-1105, 2012. doi: 10.1145/3065386.
- 117 SONG, L. *et al.* Detection of micro-defects on metal screw surfaces based on deep convolutional neural networks. **Sensors**, v. 18, n. 11, p. 3709-3723, 2018.
- 118 TOWARDS DATASCIENCE. **A comprehensive guide to convolutional neural networks**. Disponível em: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>. Acesso em: 02 ago. 2019.
- 119 ACTION TECHNOLOGY. **Motor e passo 1.8 SM1.8-D30-CS**. Disponível em: https://www.actiontechnology.com.br/motor_de_passo-copy-27. Acesso em: 04 ago. 2019.
- 120 ACTION TECHNOLOGY. **Driver para motor de passo DR-SB050DC04-CS**. Disponível em: <http://catalogoactiontechnology.wc2.mystore.build/dr-sb050dc04-cs-p140>. Acesso em: 04 ago. 2019.
- 121 SPI LASERS. **redENERGY® pulsed fiber lasers**. Disponível em: <https://www.spilasers.com/industrial-fiber-lasers/redenergy-g4/>. Acesso em: 04 ago. 2019.

-
- 122 PASSOS, F. C. S. **Desenvolvimento de um sistema de deposição de materiais metálicos a laser**. 2018. Monografia (Trabalho de Conclusão de Curso) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018.
- 123 PRINCÍPIO de Bernoulli. Disponível em: https://pt.wikipedia.org/wiki/Princípio_de_Bernoulli. Acesso em: 04 ago. 2019.
- 124 PRINCÍPIO DE BERNOULLI. **Efeito Venturi**. Disponível em: https://pt.wikipedia.org/wiki/Princípio_de_Bernoulli. Acesso em: 04 ago. 2019.
- 125 FLUIR PNEUMÁTICA. **Válvula geradora de vácuo**. Disponível em: <http://www.fluirautomacao.com.br/arquivo/vgva.pdf>. Acesso em: 04 ago. 2019.
- 126 RASPBERRY PI FOUNDATION. **Raspberry Pi 3 Model B**. Disponível em: <https://www.raspberrypi.org/products/raspberry-pi-3-model-b/>. Acesso em: 04 ago. 2019.
- 127 RASPBERRY PI FOUNDATION. **About Us**. Disponível em: <https://www.raspberrypi.org/about/>. Acesso em: 04 ago. 2019.
- 128 RASPBERRY PI FOUNDATION. **Camera Module V2**. Disponível em: <https://www.raspberrypi.org/products/camera-module-v2/>. Acesso em: 04 ago. 2019.
- 129 PANASONIC. **HG-C measurement sensor**. Disponível em: <https://www.panasonic-electric-works.com/eu/hg-c-measurement-sensor.htm>. Acesso em: 04 ago. 2019.
- 130 OPENCV.ORG. **About**. Disponível em: <https://opencv.org/about/>. Acesso em: 04 ago. 2019.
- 131 DLIB. **Dlib C++ Library**. Disponível em: <http://dlib.net/>. Acesso em: 04 ago. 2019.
- 132 TENSORFLOW.ORG. **Overview**. Disponível em: <https://www.tensorflow.org>. Acesso em: 04 ago. 2019.
- 133 QT DESIGNER. **Qt designer manual**. Disponível em: <https://doc.qt.io/qt-5/qt designer-manual.html>. Acesso em: 04 ago. 2019.
- 134 LI, W. *et al.* Selection of Gabor filters for improved texture feature extraction. *In: INTERNATIONAL CONFERENCE ON IMAGE PROCESSING*, 17., 2010, Hong Kong. **Proceedings [...]**Hong Kong: IEEE, 2010.
- 135 BUADES, A.; COLL, B.; MOREL, J. M. Non-local means denoising. **Image Processing**, v. 1, p. 208-212, 2011.
- 136 NEU-DET. **NEU surface defect database**. Disponível em: http://faculty.neu.edu.cn/yunhyan/NEU_surface_defect_database.html. Acesso em: 04 ago. 2019.
- 137 SONG, K.; YAN, Y. A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects. **Applied Surface Science**, v. 285, Part B, p. 858-864, 2013.

138 HE, Y. *et al.* An end-to-end steel surface defect detection approach via fusing multiple hierarchical features. **IEEE Transactions on Instrumentation and Measurement**, 2019. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8709818>. Acesso em: 04 ago. 2019.

139 HE, Y. *et al.* Semi-supervised defect classification of steel surface based on multi-training and generative adversarial network. **Optics and Lasers in Engineering**, v. 122, p. 294-302, 2019. doi: 10.1016/j.optlaseng.2019.06.020

140 MONGODB. **MongoDB Docs**. Disponível em: <https://www.mongodb.com/>. Acesso em: 04 ago. 2019.