

LUAN HENRIQUE MENDONÇA MOREIRA

**IDENTIFICAÇÃO E QUANTIFICAÇÃO DE DANO EM ESTRUTURAS
DE MATERIAL COMPÓSITO VIA CORRELAÇÃO DE IMAGEM
DIGITAL APLICADA AO MACHINE LEARNING**

JOINVILLE – SC

2020

LUAN HENRIQUE MENDONÇA MOREIRA

**IDENTIFICAÇÃO E QUANTIFICAÇÃO DE DANO EM ESTRUTURAS
DE MATERIAL COMPÓSITO VIA CORRELAÇÃO DE IMAGEM
DIGITAL APLICADA AO MACHINE LEARNING**

Dissertação apresentada ao programa de pós-graduação, como requisito para obtenção de título de mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Ricardo de Medeiros

Joinville – SC

2020

**Ficha catalográfica elaborada pelo programa de geração automática da
Biblioteca Setorial do CCT/UDESC,
com os dados fornecidos pelo(a) autor(a)**

Moreira, Luan Henrique Mendonça

Identificação e quantificação de dano em estruturas de material compósito via correlação de imagem digital aplicada ao machine learning / Luan Henrique Mendonça Moreira. -- 2020.

112 p.

Orientador: Ricardo de Medeiros

Coorientador: André Tavares da Silva

Dissertação (mestrado) -- Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa de Pós-Graduação em Engenharia Mecânica, Joinville, 2020.

1. Machine Learning. 2. Inteligência Artificial. 3. Correlação de Imagem Digital. 4. Compósito. 5. Ensaio de tração. I. Medeiros, Ricardo de. II. Silva, André Tavares da. III. Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa de Pós-Graduação em Engenharia Mecânica. IV. Título.

LUAN HENRIQUE MENDONÇA MOREIRA

**IDENTIFICAÇÃO E QUANTIFICAÇÃO DE DANO EM ESTRUTURAS
DE MATERIAL COMPÓSITO VIA CORRELAÇÃO DE IMAGEM
DIGITAL APLICADA AO MACHINE LEARNING**

Dissertação apresentada ao programa de pós-graduação, como requisito para obtenção de título de mestre em Engenharia Mecânica.

Banca Examinadora:

Orientador:

Prof. Dr. Ricardo de Medeiros
Universidade do Estado de Santa Catarina – UDESC

Membro:

Prof. Dr. André Taveres da Silva
Universidade do Estado de Santa Catarina – UDESC

Membro:

Dr. Rodrigo Pires dos Santos
GAVB Consulting

**Joinville – SC
18/12/2020**

Agradecimentos

Agradeço inicialmente toda minha família que sempre esteve ao meu lado em todos os momentos, especialmente ao meu pai, Petrônio por ter me dado a orientação e educação necessária para o meu desenvolvimento pessoal e profissional.

Ao professor Dr. Ricardo de Medeiros pelo acolhimento e pelo tempo dedicado à orientação e apoio na elaboração deste trabalho.

À Universidade do Estado de Santa Catarina – UDESC, pelos conhecimentos e disponibilização de materiais necessários para a elaboração deste trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES-001), o Programa de Bolsas de Monitoria de Pós-Graduação da Universidade do Estado de Santa Catarina (PROMOP/UDESC) e a Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (FAPESC – 2017TR1747, 2017TR784 e 2019TR779), pelo suporte financeiro.

RESUMO

O uso de materiais compósitos tem intensificado nas últimas décadas, nos ramos automotivo, aeronáutico, construção civil, ferroviário, pois eles apresentam uma ampla gama de combinações entre seus constituintes, capazes de produzir materiais com propriedades únicas, adequando-se às especificidades de cada projeto. Com a evolução tecnológica, grande parte das pesquisas se orientam no desenvolvimento de sistemas capazes de monitorar a integridade de máquinas, veículos e estruturas, principalmente os que oferecem riscos de acidentes e catástrofes. Em certos ramos, como o aeroespacial, a utilização de materiais compósitos requer atenção especial, devido à ocorrência de falhas do tipo delaminação, rupturas de fibras e matrizes. Neste contexto, várias técnicas não destrutivas podem ser utilizadas para monitorar estes sistemas, permitindo a realização de reparos e consequentemente, evitando maiores prejuízos econômicos e danos sociais. O presente trabalho tem o intuito de apresentar uma metodologia para realizar o monitoramento de integridade estrutural de material compósito, utilizando um ensaio de tração em conjunto com a Correlação de Imagem Digital (DIC - *Digital Image Correlation*) para a identificação e quantificação de dano através do algoritmo *Support Vector Machine* e Yolov3. A classificação das curvas dos ensaios de tração apresentaram 75% de acurácia utilizando-se do algoritmo SVM e já para classificação das imagens do DIC o algoritmo Yolov3 alcançou 78% de precisão para a classificação de amostras em três grupos. Entretanto apesar das boas acurácias o processo de criação das amostras deve ser aprimorado para ter materiais com mais repetibilidade.

PALAVRAS-CHAVE: *Machine learning*. Yolov3. Correlação de Imagem Digital. Materiais compósitos.

ABSTRACT

The use of composite materials has intensified in the last decades, in the automotive, aeronautics, civil construction, and railway sectors, as they present a wide range of solid among their constituents, capable of producing design materials with unique properties, adapting as specifications of each. With the technological evolution, the great part of the research is oriented in the development of systems capable of monitoring the integrity of the machines, vehicles and structures, mainly the risks of accidents and catastrophes. In certain sectors, such as aerospace, the use of composite materials requires special attention, due to the occurrence of delamination-type failures, fiber breaks and dies. In this context, several non-destructive techniques can be used to monitor these systems, allowing repairs to be carried out and, consequently, avoiding greater economic and social damages. This work intends to present a methodology to carry out the structural integrity monitoring of composite material, using a tensile test in conjunction with the Digital Image Correlation (DIC - Digital Image Correlation) for the identification and quantification of damage through the Suport Vector Machine and Yolov3 algorithm. The classification of the curves of the traction tests showed 75% accuracy using the SVM algorithm and for the classification of the DIC images, the Yolov3 algorithm reached 78% accuracy for the classification of samples in three groups. However, despite the good accuracy, the process of creating samples should be improved to have more repeatable materials.

KEYWORDS: *Machine learning.* Yolov3. Digital Image Correlation. Composite materials.

LISTA DE FIGURAS

Figura 1 - Rótulos de Treinamento.....	22
Figura 2 - Exemplo de Regressão.....	22
Figura 3 - Distância entre planos.....	25
Figura 4 - (a) Conjunto de dados não lineares; (b) Fronteira não linear no espaço de entradas; (c) Fronteira lineares no espaço de características.	29
Figura 5 – Perceptron.....	33
Figura 6 - Composição de redes de múltiplas camadas.....	34
Figura 7 - Exemplo de dados Under Fit, Adequado, Over Fit.....	35
Figura 8 - Exemplos de Detecção	40
Figura 9 - Esquema de predição	41
Figura 10 - Arquitetura YOLOv3.....	43
Figura 11 - Representação matricial de imagem binária	44
Figura 12 - Processamento Digital de Imagem, Inversão de matriz de luminosidade 5x5	45
Figura 13 - Lake (tamanho 5306 x 3770)	47
Figura 14 - Histograma do Lake em escala de cinza	48
Figura 15 - Classificação de compósitos.....	51
Figura 16 - Lâminas com reforços: (a) unidirecional; (b) tecido bidirecional; (c) fibras picadas; (d) manta contínua, submetida a esforços de tração uniaxial longitudinais.	52
Figura 17 - Tipos de compósitos	53
Figura 18 – Adesão	54
Figura 19 - Tipos de falhas em compósitos.....	56
Figura 20 - Modos de falha interlaminar e translaminar	57
Figura 21 - Folhas sobre a seção transversal	59
Figura 22 - Exemplo de uma aplicação de algoritmo de machine learn de detecção de anomalia.....	66
Figura 23 - Fluxograma do experimento	67
Figura 24 - Layout de produção de amostras.....	68
Figura 25 - Sem dano – Com 08 camadas contínuas, com ângulo de 0°	69

Figura 26 - Dano 01 – Com 02 camadas centrais com cortes na seção horizontal...	69
Figura 27 - Dano 02 – Com 04 camadas centrais com cortes na seção horizontal...	70
Figura 28 - Estrutura para colocação de fibras.....	70
Figura 29 – Estrutura de fabricação completa.....	71
Figura 30 – Serra de corte usada para produção dos corpos de prova	71
Figura 31 - Máquina de tração EMIC dl 3000.....	73
Figura 32 - Filmagem do ensaio de tração pelo equipamento DIC	73
Figura 33 - Cálculo de parâmetros de projeção	74
Figura 34 - Detecção dos marcadores	75
Figura 35 - Frequência de aquisição	75
Figura 36 - Exemplo de configuração.....	76
Figura 37 - Exemplo de Correlação de imagem digital (d1-cdp1)	76
Figura 38 - Seleção de regime elástico	78
Figura 39 - D0-cdp1	78
Figura 40 - Seleção de classe	79
Figura 41 - Dicionário e localização de classe	79
Figura 42 - Google Colab GPU	81
Figura 43 - Acesso ao Google drive via Colab	82
Figura 44 - Cópia dos arquivos darknet	82
Figura 45 - Nome da classe selecionada nas imagens	82
Figura 46 - Alteração do arquivo de configuração para uma classe.....	83
Figura 47 - Treinamento da rede.....	83
Figura 48 - Performance Yolov3.....	84
Figura 49 - d0-cdp16	85
Figura 50 - d0-cdp17	85
Figura 51 - d0-cdp18	85
Figura 52 - d1-cdp16	86
Figura 53 - d1-cdp17	86
Figura 54 - d1-cdp18	86
Figura 55 - d2-cdp16	87
Figura 56 - d2-cdp17	87
Figura 57 - d2-cdp18	87

Figura 58 - Tração das amostras 1,2 e 5 “Dano0”, com diferentes limites de escoamento.....	88
Figura 59 - Tração das amostras 1,3 e 5 “Dano1”, com diferentes limites de escoamento.....	89
Figura 61 - D0-CDP16 Ocorrência do dano foto (976)	93
Figura 62 - D0-CDP16 Ocorrência do dano detectada pelo Yolov3	94
Figura 63 - Gráfico ensaio de tração d0-cdp16	94
Figura 64 – D1-CDP16 Ocorrência do dano foto (727)	95
Figura 65 - D1-CDP16 Ocorrência do dano detectada pelo Yolov3	96
Figura 66- Gráfico ensaio de tração d1-cdp16	97
Figura 67 – D2-CDP16 Ocorrência do dano foto (669)	98
Figura 68 - D1-CDP16 Ocorrência do dano detectada pelo Yolov3	98
Figura 69 - Gráfico ensaio de tração d2-cdp16	99

LISTA DE TABELAS

Tabela 1 - Kernels mais utilizados.....	31
Tabela 2 - Propriedades das fibras de vidro.....	56
Tabela 3 - Dimensões amostras.....	72
Tabela 4 - Ponto de escoamento dos corpos de prova	89
Tabela 5 - Acurácia do modelo.....	91
Tabela 6 - Precisão por amostra	91
Tabela 7 - Comparação do tempo da presença de dano por imagens e ensaio de tração.	93
Tabela 8 - Ensaio de tração, identificação dano d0-cdp16.....	94
Tabela 9 - Ensaio de tração, identificação dano d1-cdp16.....	97
Tabela 10 - Ensaio de tração, identificação dano d2-cdp16.....	99

LISTA DE ABREVIACÃO

ABTN – Associação de Normas Técnicas

ASTM – American Society for Testing and Materials

BEM - Boundary Element Method

BVID – Barely Visible Impact Damage

CNN – Convolutional Neural network

CONVNETS – Redes Neurais Convolucionais

CPUs – Central Processing Unit

CUDA – Compute Unified Device Architecture

DCB – Double Cantilever Beam

DIC – Digital Image Correlation

GFRC – Glass Fiber Reinforced Concrete

GFRP – Glass Fiber Polymer

RGB – Red, Green e Blue

GPU – Graphics Processing Unit

I.A – Artificial Intelligence

JPEG – Joint Pictures Expert Group

KNN – K Nearest Neighbor

MAP – Mean Average Precision

MLP – Neurais Perceptron Multicamadas

NPL – Natural Language Processing

OCR – Reconhecimento ótico de caracteres

OVR – One Versus Rest

RBF – Radial-Basis Function

RELU – Rectified Linear Units

RFC – Random Forest Classifier

RNA – Rede Neural Artificial

R-CNN – Regiões com Convolutional Neural network

SLT – Statistical Theory Learning

SMH – System Health Monitoring

SVM – Suport Vector Machine

SVs – Vetores de Suportes

TXT - Text

YOLO – You Only Look Once

V2 – Versão 2

V3 – Versão 3

SUMÁRIO

1. INTRODUÇÃO.....	15
1.1. MOTIVAÇÃO.....	16
1.2. OBJETIVO	17
2. FUNDAMENTAÇÃO TEÓRICA	18
2.1. INTELIGÊNCIA ARTIFICIAL	18
2.2. APRENDIZADO DE MÁQUINA.....	19
2.3. RECONHECIMENTO DE PADRÃO.....	20
2.3.1. MÉTODOS DE RECONHECIMENTO DE PADRÃO APLICADOS A MONITORAMENTOS PARA A ENGENHARIA.....	21
2.4. APRENDIZADO SUPERVISIONADO	21
2.5. SVM (SUPORT VECTOR MACHINE).....	23
2.5.1. SVMS LINEARES.....	23
2.5.2. SVMS NÃO LINEARES	28
2.6. REDES NEURAIS.....	32
2.6.1. APRENDIZAGEM PROFUNDA.....	36
2.6.2. REDES NEURAIS CONVOLUCIONAIS	37
2.6.3. TRANSFER LEARNING	38
2.6.4. YOLO.....	39
2.6.4.1. YOLOV3.....	42
2.7. CORRELAÇÃO DE IMAGEM DIGITAL.....	44
2.8. TÉCNICA DE CORRELAÇÃO DE IMAGENS DIGITAIS (DIC)	46
2.9. HISTOGRAMA DE CORES	47
2.10. CORRELAÇÃO DIGITAL DE IMAGENS APLICADO À ENGENHARIA.....	48
2.11. MATERIAIS COMPÓSITOS.....	50
2.11.1. CLASSIFICAÇÃO DE COMPÓSITOS.....	51
2.11.1.1. MATRIZ POLIMÉRICA.....	55
2.11.1.2. REFORÇOS.....	55
2.11.1.2.1. FIBRAS DE VIDRO.....	56
2.11.2. FALHA EM MATERIAIS COMPÓSITOS	56
2.11.2.1. FALHAS EM LÂMINAS UNIDIRECIONAIS.....	58
2.11.2.2. TRAÇÃO LONGITUDINAL.....	58
2.11.2.3. TRAÇÃO TRANSVERSAL.....	59
2.12. MONITORAMENTO DE SAÚDE ESTRUTURAL (SHM).....	60
2.12.1. AVALIAÇÃO OPERACIONAL.....	61
2.12.2. AQUISIÇÃO DE DADOS, NORMALIZAÇÃO E LIMPEZA.....	62
2.12.3. EXTRAÇÃO DE RECURSOS E CONDENSAÇÃO DE INFORMAÇÕES..	62

2.12.4.	DESENVOLVIMENTO DE MODELO ESTATÍSTICO PARA DISCRIMINAÇÃO DE CARACTERÍSTICAS	62
2.12.5.	SHM APLICADOS EM MATERIAIS COMPÓSITOS	63
3.	MATERIAIS E METODOLOGIA.....	67
3.1.	DETECÇÃO DE DANOS EM AMOSTRAS DE FIBRA DE VIDRO – EPÓXI.....	68
3.2.	PROCESSOS DE FABRICAÇÃO DE AMOSTRAS	68
3.3.	ENSAIO DE TRAÇÃO E FILMAGEM.....	72
3.4.	DIC	74
3.5.	TRATAMENTO DE DADOS.....	77
3.5.1.	TRATAMENTO DOS DADOS DO ENSAIO DE TRAÇÃO	77
3.5.2.	TRATAMENTO DOS DADOS DO DIC	79
3.6.	APLICAÇÃO DOS DADOS DE TRAÇÃO NO ALGORITMO SVM.....	80
3.7.	APLICAÇÃO DOS DADOS DE IMAGENS DO ENSAIO DE TRAÇÃO NO ALGORITMO YOLOV3	81
3.8.	DETECÇÃO POR VÍDEO	84
4.	RESULTADOS E DISCUSSÃO	88
4.1.	COMPORTAMENTO DAS AMOSTRAS	88
4.1.1.	EMPILHAMENTO E ORIENTAÇÃO DE FIBRAS	90
4.2.	RESULTADOS SVM	90
4.3.	RESULTADOS YOLOV3.....	92
5.	CONCLUSÃO.....	101
	REFERÊNCIAS BIBLIOGRÁFICAS.....	103

1. INTRODUÇÃO

O uso de materiais compósitos tem se intensificado ao longo dos anos devido a suas propriedades mecânicas excepcionais, que são logradas através da união de reforços e matrizes, além da abrangência de suas aplicações nas áreas aeronáutica, naval, engenharia civil, entre outras (REZENDE *et al.*, 2000). Um exemplo dos benefícios dos compósitos está no quesito peso em comparação aos metais e madeiras; o compósito é muito mais leve, o que justifica a sua utilização em aviões, promovendo a maior eficiência do uso dos combustíveis. Entretanto, a integridade estrutural de materiais compósitos e a segurança dos elementos de uma aeronave devem ser testadas periodicamente durante a sua vida operacional. Para a manutenção dos elementos estruturais das aeronaves a avaliação da integridade estrutural, evolução dos danos existentes e a vida residual destes elementos têm importância fundamental (REZENDE *et al.*, 2000).

A avaliação da integridade estrutural utiliza métodos avançados de ensaios não destrutivos para detectar, localizar e quantificar o dano da estrutura. Além da precisão na detecção e localização dos danos, essas técnicas de ensaios não destrutivos devem permitir a detecção precoce de possíveis danos.

A implantação de estratégias de identificação de danos para a infraestrutura de engenharia aeroespacial, civil e mecânica é chamado de Monitoramento da Integridade Estrutural (SHM, *Structural Health Monitoring*). Esse processo envolve a observação de uma estrutura ao longo do tempo, usando medições periódicas que visam extrair características sensíveis a danos. Com estes dados é possível realizar uma análise estatística para determinar a integridade da estrutura. Para o monitoramento estrutural de longo prazo, a resposta do sistema é atualizada periodicamente em relação à capacidade da estrutura de desempenhar sua função, levando em conta o envelhecimento e o acúmulo de danos resultantes dos ambientes operacionais. Em eventos adversos, como carregamentos inesperados ou influência externas, o SHM é usado para uma rápida avaliação do sistema. Essa triagem tem função de prover rápidas e confiáveis informações sobre o desempenho atual e futuro do sistema (FARRAR *et al.*, 2006).

Com base em parâmetros do sistema, é atribuída uma classe de dano que é usada para indicar a existência e fornecer informações sobre o local e a extensão do dano. Dos três principais tipos de reconhecimento de padrões, estatístico, sintático e neural, apenas o estatístico e o neural foram perseguidos com vigor para a solução de problemas de engenharia (WORDEN *et al.*, 2001).

A Teoria da Aprendizagem Estatística (SLT, *Statistical Theory Learning*) é um desenvolvimento comparativamente recente. Em muitos aspectos, ela unifica os conceitos de classificadores de padrões estatísticos e neurais e amplia sua capacidade de generalizar a partir de pequenos conjuntos de dados. Esse último ponto é importante, uma vez que os conjuntos de dados encontrados em problemas de engenharia normalmente tendem a ser pequenos pelos padrões estatísticos. Um dos pilares do SLT é a Máquina de Vetores de Suporte (SVM *Support Vector Machine*). Essa é uma técnica de relacionamentos de dados, que pode ser usada para problemas de classificação e regressão. O SVM é também um classificador universal no sentido que pode ser usado para ajustar muitas classes diferentes de funções discriminantes (linear, rede neural, base radial), sem modificação real no algoritmo básico de aprendizado (WORDEN *et al.*, 2001).

Atualmente, o uso de correlação de imagens para identificação de dano em materiais compósitos está em estado inicial de desenvolvimento; entretanto, já existem alguns trabalhos que se utilizam dessa tecnologia para detecção de dano de fadiga (RISBET *et al.*, 2010), investigação de dano através de técnicas de medição (GOIDESCU *et al.*, 2013), assim como monitoramento de materiais laminados (CAMINERO *et al.*, 2013).

1.1. MOTIVAÇÃO

O processo de classificação de dados através de algoritmos de *Machine Learn*, como o SVM e Yolov3, vem sendo utilizado em grande escala devido a sua grande versatilidade e aplicabilidade para indefinição de imagens. Podemos destacar alguns trabalhos na literatura.

- Sensoriamento remoto, Mountrakis, *et.al.* (2011).

- Reconhecimento facial, Osuna, *et.al.* (1997, June)
- Reconhecimento de dígitos escritos a mão. Lecun, Y. *et al.* (1990)
- Detecção de pedestres via câmeras, Valiati, G. (2019)

Diante do exposto, este trabalho tem como base motivacional o uso dos sistemas de identificação de padrões devido ao seu potencial de redução de custos no meio industrial, devido à eficiência na identificação de danos em materiais (WORDEN AND LANE, 2001).

1.2. OBJETIVO

Em congruência com os pontos já citados, observa-se que o estudo de reconhecimento de padrões através de dados gerados por imagens para a identificação das propriedades e das condições de materiais aplicados à engenharia ainda se encontra em estágios iniciais. Tendo em vista essa oportunidade e a importância da verificação da integridade dos componentes em um projeto, optou-se por torná-los objetos de estudo deste trabalho. Portanto este trabalho visa desenvolver uma metodologia para avaliação de estruturas de material compósito através da correlação de imagem digital e reconhecimento de padrões. Considerando a abrangência deste trabalho, optou-se por subdividir o objetivo geral da seguinte maneira:

- Realizar o procedimento de obtenção de dados do ensaio de tração dos materiais compósitos por captação de vídeo, utilizando o equipamento de Correlação de Imagens Digitais.
- Aplicar os dados de tração no algoritmo SVM para treinamento do mesmo, com a finalidade de identificar amostras defeituosas.
- Aplicar as imagens das amostras no algoritmo Yolov3 para detectar a ocorrência do dano através de vídeo.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é uma área que se utiliza de informação computadorizada para generalizar métodos de automação de atividades manipulativas, perceptivas e cognitivas (MONIZ, 2003).

A inteligência artificial trabalha com duas vertentes: a que faz o uso de padrões e retira suas regras de grandes conjuntos de dados, conhecido como indutivo; e o dedutivo que busca informações sejam elas válidas ou inválidas e passam essa afirmação generalizada para uma conclusão. O aprendizado de máquina só se preocupa com o indutivo (PFEIFER, 2010).

Muitos cientistas usam o nome IA para se referir a computadores ou máquinas que tentam exercer funções antes feitas pela mente humana (GENESERETH, 2012).

A inteligência artificial foi fundada como uma disciplina acadêmica em 1955 e, desde então, experimentou várias ondas de otimismo (SIMON, 1965; CREVIER, 1993), seguidas de vários projetos com resultados inconclusivos, o que provocou a frustração dos investidores; ocasionando a falta de financiamento (conhecida como "inverno IA"), (CREVIER, 1993; RUSSELL, 2002). Em seguida, com novas abordagens de sucesso, o setor ganhou fôlego renovando assim os financiamentos (CREVIER, 1993; CLARK, 2015). Durante a maior parte de sua história, a pesquisa em IA foi dividida em sub campos que geralmente não conseguem se comunicar. Os subcampos originados da divisão foram: visão computacional, NPL (*natural language processing*), teoria de decisão, algoritmos genéticos e robótica (MCCORDUCK, 2004).

A origem de AI remonta aos Diálogos de Platão, passando por Descartes e Leibnitz, até chegar a três grandes pensadores: Janos von Neumann (Sistemas climáticos e aquecimento global), Norbert Wiener (*Cibernética e sociedade: o uso humano de seres humanos, 1950 - revisado em 1954*) e Alan Turing (Desenvolveu uma máquina chamada "Enigma", capaz de decifrar o código utilizado pelos nazistas, durante a Segunda Guerra Mundial); a partir de então, passou a ser trabalho de muitos cientistas.

2.2. APRENDIZADO DE MÁQUINA

Visto como um subconjunto da Inteligência Artificial o *machine learning* é o estudo de algoritmos de computador que se baseia em lógicas matemáticas para tomadas de decisões (KOZA, 1996).

O *machine learning* está diretamente relacionado à estatística computacional, que se concentra em fazer previsões usando computadores através de modelos estatísticos. A otimização matemática fornece métodos, teoria e domínios de aplicação ao campo do *machine learning* (BISHOP, 2006). Esta mineração de dados é um processo iterativo no qual o progresso é definido pela descoberta, por meio de métodos automáticos ou manuais. A mineração de dados; é mais útil em um cenário de análise exploratória em que não há noções predeterminadas sobre o que constituirá um resultado “satisfatório”. A mineração de dados é a busca de novas informações valiosas e não triviais em grandes volumes de dados é um esforço entre humanos e computadores. Os melhores resultados são alcançados equilibrando o conhecimento de especialistas humanos na descrição de problemas e objetivos com os recursos de pesquisa dos computadores (GORUNESCU, 2011).

O *machine learning* pode ser definido como métodos computacionais, usando experiências para aprimorar a performance ou fazer previsões precisas. Aqui, a experiência refere-se às informações passadas disponíveis para o aprendizado da máquina, que geralmente assumem a forma de dados eletrônicos coletados e disponibilizados para análise.

Esses dados podem estar na forma digitalizadas já classificadas e, para o treinamento ou outros tipos de informações, podem ser obtidas por meio da interação com o ambiente. Em todos os casos, sua qualidade e tamanho são cruciais para o sucesso das previsões realizadas pela máquina.

Um exemplo de problema de aprendizado de máquina pode ser definido como a categorização de uma amostra finita de documentos selecionados aleatoriamente, cada um com um tópico, para prever com precisão o tópico de documentos não vistos. Claramente, quanto maior a amostra, maior a precisão de categorização. Entretanto, a qualidade dos rótulos é um importante fator para um bom treinamento já que podem existir erros na classificação da categoria dos livros.

O aprendizado de máquina consiste em projetar algoritmos de previsão eficientes e precisos. Assim como em outras áreas da ciência da computação, a qualidade do algoritmo é definida pelo tempo e a complexidade. Mas, no aprendizado de máquina, é necessário saber a complexidade amostral para entender a quantidade de dados requeridos para aprender um conceito (MOHRI, 2018).

Os sistemas de *Machine learning* podem ser classificados com o tipo de supervisão que recebem durante o treinamento. Existem quatro categorias principais: aprendizado supervisionado, aprendizado não supervisionado, aprendizado semi-supervisionado e aprendizado por reforço (GÉRON, 2019).

2.3. RECONHECIMENTO DE PADRÃO

O reconhecimento de padrões tem sua origem na engenharia, enquanto o aprendizado de máquina surgiu da ciência da computação (BISHOP, 2006). No entanto, essas atividades podem ser vistas como duas facetas do mesmo campo e, juntas, passaram por um desenvolvimento substancial nos últimos dez anos. Em particular, os métodos bayesianos cresceram de um nicho especializado para se tornarem *mainstream*, enquanto os modelos gráficos surgiram como uma estrutura geral para descrever e aplicar modelos probabilísticos. Além disso, a aplicabilidade prática dos métodos bayesianos foi aprimorada por meio do desenvolvimento de algoritmos de inferência aproximada, como *Bayes* variacional e propagação de expectativa. Da mesma forma, novos modelos baseados em kernels tiveram um impacto significativo em algoritmos e aplicativos (BISHOP, 2006).

O problema de busca de padrões em dados é fundamental e tem uma longa e bem-sucedida história. Por exemplo, as extensas observações astronômicas de Tycho Brahe, no século 16, permitiram a Johannes Kepler descobrir as leis empíricas do movimento planetário, o que, por sua vez, forneceu um trampolim para o desenvolvimento da mecânica clássica. Da mesma forma, a descoberta de regularidades em espectros atômicos desempenhou um papel fundamental no desenvolvimento e verificação da física quântica no início do século XX.

O campo do reconhecimento de padrões preocupa-se com a descoberta automática de periodicidade nos dados por meio do uso de algoritmos de computador

e, também, com o uso dessas regularidades para realizar ações, como classificar os dados em diferentes categorias (BISHOP, 2006).

2.3.1. MÉTODOS DE RECONHECIMENTO DE PADRÃO APLICADOS A MONITORAMENTOS PARA A ENGENHARIA.

Muitos sistemas de monitoramento de máquinas baseados em modelos de processos de inteligência artificial (IA) foram desenvolvidos com sucesso no passado para otimizar, prever ou controlar processos de máquinas. Em geral, esses sistemas de monitoramento apresentam diferenças importantes entre eles e não há diretrizes claras para sua implementação (ABELLAN, 2010).

Um exemplo de trabalho recente para a área foi a descrição de um escopo de trabalho de monitoramento de integridade estrutural (SHM) utilizando-se de técnicas como *Big Data* e Inteligência Artificial. O estudo faz um sumário dos requerimentos para fazer a união entre IA e SHM (SUN, *et al.*, 2020).


Também recente publicando, um estudo sobre o uso de três algoritmo de *machine learn* (KNN K-Nearest Neighbor, RFC Random Forest Classifier e SVM Support Vector Machine) usando dados de sensores para prever danos estruturais em concreto (KURIAN, 2020).

2.4. APRENDIZADO SUPERVISIONADO

No aprendizado supervisionado, os dados de treinamento que são fornecidos para o algoritmo incluem as soluções desejadas, chamadas de rótulos (Figura 1).


Um exemplo típico de conjunto de treinamento para aprendizado supervisionado é o filtro de spam. O sistema é treinado com muitos exemplos de e-mails do tipo spam ou não spam para aprender a fazer novas classificações de e-mails. A regressão é outra função dos algoritmos de *machine learning* que tem como objetivo obter um valor numérico; exemplo: prever o valor de um carro, dados as seguintes características (marca, idade, quilometragem, etc.). Assim como na classificação, são necessários vários exemplos de preços carros com suas características para permitir o seu treinamento (Figura 2) (GÉRON, 2019).

Figura 1 - Rótulos de Treinamento



Fonte: GÉRON (2019).

Figura 2 - Exemplo de Regressão



Fonte: Géron (2019).

Géron (2019) citou alguns exemplos dos mais importantes algoritmos de aprendizado supervisionado:

- k-Nearest Neighbours
- Regressão Linear
- Regressão Logística
- Máquinas de Vetores de Suporte (SVM)
- Árvores de Decisão e Florestas Aleatórias

- Redes Neurais

2.5. SVM (SUPORT VECTOR MACHINE)

Support Vector Machine (SVMs) é um método para a classificação de dados lineares e não-lineares no qual se utiliza mapeamento não linear para transformar os dados de treinamento originais em uma dimensão mais alta. Dentro dessa nova dimensão, ele procura pelo hiperplano de separação linear ideal, ou seja, um "limite de decisão" que separa as tuplas de uma classe da outra. Com um mapeamento não linear apropriado para uma dimensão suficientemente alta, os dados de duas classes podem ser separados por um hiperplano.

O SVM encontra este hiperplano usando vetores de suporte (tuplas de treinamento "essenciais") e margens (definidas pelos vetores de suporte). O primeiro artigo sobre máquinas de vetores de suporte foi apresentado em 1992 por Vladimir Vapnik e seus colegas Bernhard Boser e Isabelle Guyon, embora a base para SVMs tenha sido desde a década de 1960 (incluindo os primeiros trabalhos de Vapnik e Alexei Chervonenkis sobre teoria de aprendizagem estatística).

Os SVMs mais atuais podem ser extremamente lentos, entretanto eles são altamente precisos devido à sua capacidade de modelar limites complexos de decisão não-lineares. Eles foram aplicados com sucesso em muitos campos, como categorização de texto, reconhecimento de fala, análise de imagens de sensoriamento remoto, previsão de séries temporais, segurança da informação e assim por diante (DENG, 2012).

2.5.1. SVMS LINEARES

As SVMs lineares constroem fronteiras lineares para dados linearmente separáveis. Seja X um conjunto de dados para treinamento com n objetos $x_i \in X$ e seus respectivos rótulos $y_i \in Y$, em que X constitui o espaço de entrada (características) e $Y = \{-1, +1\}$ são as possíveis classes. X é linearmente separável se é possível separar os objetos das classes $+1$ e -1 por um hiperplano.

A equação de um hiperplano pode ser definida por

$$h(x) = \mathbf{w} \cdot \mathbf{x} + b = 0, \quad (1)$$

em que $\mathbf{w} \cdot \mathbf{x}$ é o produto escalar entre os vetores \mathbf{w} e \mathbf{x} , $\mathbf{w} \in X$ é o vetor normal ao hiperplano descrito e $\frac{b}{\|\mathbf{w}\|}$ corresponde à distância do hiperplano em relação à origem com $b \in \mathbb{R}$.

Essa equação pode ser usada para dividir o espaço de entrada X em duas regiões: $\mathbf{w} \cdot \mathbf{x} + b > 0$ e $\mathbf{w} \cdot \mathbf{x} + b < 0$. Uma função sinal $g(x) = \text{sgn}(h(x))$ pode ser usada para se obter as classificações, conforme

$$g(x) = \text{sgn}(h(x)) = \begin{cases} +1 & \text{se } \mathbf{w} \cdot \mathbf{x} + b > 0 \\ -1 & \text{se } \mathbf{w} \cdot \mathbf{x} + b < 0 \end{cases}. \quad (2)$$

Com $h(x)$, um número infinito de hiperplanos pode ser obtido pela multiplicação de \mathbf{w} e b por uma mesma constante. Define-se hiperplano canônico em relação ao conjunto X como aquele em que \mathbf{w} e b são escalados de forma que os exemplos mais próximos ao hiperplano $\mathbf{w} \cdot \mathbf{x} + b = 0$ satisfazem:

$$|\mathbf{w} \cdot \mathbf{x} + b| = 1. \quad (3)$$

Sendo:

$$\begin{cases} \mathbf{w} \cdot \mathbf{x} + b \geq +1, y_i = +1 \\ \mathbf{w} \cdot \mathbf{x} + b \leq -1, y_i = -1 \end{cases}. \quad (4)$$


Que pode ser resumido como:

$$y_i(\mathbf{w} \cdot \mathbf{x} + b) - 1 \geq 0 \quad \forall (x_i, y_i) \in X. \quad (5)$$

Se x_1 é um ponto no hiperplano: $H_1: \mathbf{w} \cdot \mathbf{x} + b = +1$ e x_2 um ponto no hiperplano $H_2: \mathbf{w} \cdot \mathbf{x} + b = -1$ (conforme ilustrado em Figura 3) projetando $x_1 - x_2$ na direção \mathbf{w} , perpendicular ao hiperplano separador $\mathbf{w} \cdot \mathbf{x} + b = 0$, é possível obter a distância entre os hiperplanos H_1 e H_2 , apresentado por

$$(x_1 - x_2) \left(\frac{\mathbf{w}}{\|\mathbf{w}\|} \cdot \frac{(x_1 - x_2)}{\|x_1 - x_2\|} \right). \quad (6)$$

Figura 3 - Distância entre planos



Fonte: Lorena (2007).

Sendo $\mathbf{w} \cdot \mathbf{x}_1 + b = 1$ e $\mathbf{w} \cdot \mathbf{x}_2 + b = -1$, tem-se a diferença entre $\mathbf{w} \cdot (\mathbf{x}_1 - \mathbf{x}_2) = 2$. Assim substituindo na Equação (6) obtém-se:

$$\frac{2}{\|\mathbf{w}\|} \frac{(\mathbf{x}_1 - \mathbf{x}_2)}{\|\mathbf{x}_1 - \mathbf{x}_2\|}. \quad (7)$$

Para calcular o comprimento do vetor projetado, basta isolar a norma da Equação (6), obtendo:

$$\frac{2}{\|\mathbf{w}\|}. \quad (8)$$

Este comprimento do vetor pode ser visto na Figura 3.

Segundo Burges (1998), a maximização da margem de separação dos dados pode ser obtida pela minimização de $\frac{\|\mathbf{w}\|^2}{2}$. Assim obtemos:

$$\text{Minimizar } \frac{1}{2} \|\mathbf{w}\|^2. \quad (9)$$

Com restrições:

$$y_i(\mathbf{w} \cdot \mathbf{x} + b) - 1 \geq 0, \forall_i = 1, \dots, n. \quad (10)$$

As restrições são usadas para impedir que os dados do treinamento não estejam na área de separação de classe. A função a ser minimizada é quadrática convexa e os pontos que satisfazem a restrição formam um conjunto convexo no qual esse problema possui um único mínimo global. Usando a função Lagrangiana para obter o mínimo temos:

$$\mathcal{L}(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1). \quad (11)$$

A função Lagrangiana deve ser minimizada, o que implica em maximizar as variáveis α_i e minimizar \mathbf{w} e b . Tem-se então um ponto de sela, no qual

$$\frac{\partial L}{\partial b} = 0 \text{ \& } \frac{\partial L}{\partial \mathbf{w}} = 0. \quad (12)$$

Realizando as derivadas obtemos

$$\sum_{i=1}^n \alpha_i \cdot y_i = 0, \quad (13)$$

$$\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i. \quad (14)$$

Substituindo as equações (13) e (14) na função Lagrangiana (11), obtemos:

$$\underset{\alpha}{\text{Maximizar}} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j). \quad (15)$$

Com restrições:

$$\begin{cases} \alpha_i \geq 0, \forall i = 1, \dots, n \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases}. \quad (16)$$

Essa formulação é denominada forma dual, enquanto o problema original é referenciado como forma primal. A forma dual possui os atrativos de apresentar restrições mais simples e permitir a representação do problema de otimização em termos de produtos internos entre objetos.

Seja α^* a solução do problema dual e \mathbf{w}^* e b^* as soluções da forma primal, o valor de α^* , \mathbf{w}^* pode ser determinado pela Equação (14). O parâmetro b^* é definido por α^* e pelas condições de Kuhn-Tucker, provenientes da teoria de otimização com restrições e que devem ser satisfeitas no ponto ótimo. Para o problema dual formulado temos:

$$\alpha_i^* (y_i (\mathbf{w}^* \cdot \mathbf{x}_i + b^*) - 1) = 0, \forall i = 1, \dots, n. \quad (17)$$

Observa-se nessa equação que α_i^* pode ser diferente de 0 somente para os dados que se encontram sobre os hiperplanos H_1 e H_2 . Estes são os exemplos que se situam mais próximos ao hiperplano separador, exatamente sobre as margens. Para os outros casos, a condição apresentada na Equação (17) é obedecida apenas com $\alpha_i^* = 0$. Esses pontos não participam então do cálculo de \mathbf{w}^* equação (14). Os dados que possuem $\alpha_i^* > 0$ são denominados vetores de suporte e participam na determinação da equação do hiperplano separador.

O valor de b é calculado a partir dos SVs e das condições representadas na Equação (17). Computa-se a média apresentada na Equação (18) sobre todos x_j tal que $\alpha_i^* > 0$, ou seja, todos os SVs.

Nessa equação, n_{sv} denota o número de SVs e SV representa o conjunto dos SVs, representado por:

$$b^* = \frac{1}{n_{sv}} \sum_{x_j \in SV} \frac{1}{y_j} - \mathbf{w}^* \cdot \mathbf{x}_j. \quad (18)$$

Substituindo \mathbf{w}^* pela equação (14), obtemos:

$$b^* = \frac{1}{n_{sv}} \sum_{x_j \in SV} \left(\frac{1}{y_j} - \sum_{x_i \in SV} \alpha_i^* y_i x_i x_j \right). \quad (19)$$

Como resultado final tem-se que o classificador $g(\mathbf{x})$, apresentado na Equação (20) em que sgn representa o sinal, \mathbf{w}^* é fornecido pela equação (14) e b^* pela equação (19), dado por:


$$g(\mathbf{x}) = sgn(f(\mathbf{x})) = sgn \left(\sum_{x_i \in SV} y_i \alpha_i^* x_i \mathbf{x} + b^* \right) \quad (20)$$

2.5.2. SVMS NÃO LINEARES

SVMs não lineares são capazes de encontrar limites de decisão não lineares, isto é, hipersuperfícies não lineares. Obtemos um SVM não-linear estendendo a abordagem de SVMs lineares em duas etapas. Na primeira etapa transformamos os dados de entrada originais em um espaço dimensional maior usando um mapeamento não linear. Vários mapeamentos não-lineares comuns podem ser usados nesta etapa. Uma vez que os dados foram transformados no novo espaço de dimensão maior, o segundo passo foi procurar um hiperplano de separação linear no novo espaço. Novamente, terminamos com um problema de otimização quadrática que pode ser

resolvido usando a formulação linear de SVM. O hiperplano marginal máximo encontrado no novo espaço corresponde a uma hipersuperfície de separação não linear no espaço original. Para ilustrar esses conceitos, considere o conjunto de dados apresentado na Figura 4.

Figura 4 - (a) Conjunto de dados não lineares; (b) Fronteira não linear no espaço de entradas; (c) Fronteira lineares no espaço de características.



Fonte: Lorena (2011).

Transformando os dados de \mathfrak{R}^2 para \mathfrak{R}^3 com o mapeamento representado na Equação (9), o conjunto de dados não linear em \mathfrak{R}^2 torna-se linearmente separável em \mathfrak{R}^3 (Figura 4 - (a) Conjunto de dados não lineares; (b) Fronteira não linear no espaço de entradas; (c) Fronteira lineares no espaço de características.

c). É possível então encontrar um hiperplano capaz de separar esses dados, conforme descrito na Equação (22). Pode-se verificar que a função apresentada, embora linear em \mathfrak{R}^3 (Figura 4c) corresponde a uma fronteira não linear em \mathfrak{R}^2 (Figura 4b), definida por

$$\Phi(\mathbf{x}) = \Phi(x_1, x_2) = (x_1^2, \sqrt{2}x_1x_2, x_2^2), \quad (21)$$

$$f(\mathbf{x}) = \mathbf{w} \cdot \Phi(\mathbf{x}) + b = w_1x_1^2 + w_2\sqrt{2}x_1x_2 + w_3x_2^2 + b = 0. \quad (22)$$

Logo, mapeia-se, inicialmente, os dados para um espaço de maior dimensão utilizando Φ e aplica-se a SVM linear sobre este espaço. Esse encontra o hiperplano com maior margem de separação, garantindo assim uma boa generalização. Utiliza-se a versão de SVM linear com margens suaves, que permite lidar com ruídos e *outliers* presentes nos dados. Para realizar o mapeamento, aplica-se Φ aos exemplos presentes no problema de otimização representado por

$$\underset{\alpha}{\text{Maximizar}} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\Phi(x_i) \cdot \Phi(x_j)) . \quad (23)$$

Sob as restrições

$$g(x) = \text{sgn}(f(x)) = \text{sgn} \left(\sum_{x_i \in SV} y_i \alpha_i^* \Phi(x_i) \cdot \Phi(x) + b^* \right) . \quad (24)$$

Em que b^* é adaptado (18), obtendo-se

$$b^* = \frac{1}{n_{SV:\alpha^* < C}} \sum_{x_j \in n_{SV:\alpha^* < C}} \left(\frac{1}{y_j} - \sum_{x_i \in SV} \alpha_i^* y_i \Phi(x_i) \cdot \Phi(x_j) \right) . \quad (25)$$

Como o espaço de característica (X) pode ter dimensão muito alta (até mesmo infinita), a computação de Φ pode ser extremamente custosa ou inviável. Porém, percebe-se pelas equações (23)-(25) que a única informação necessária sobre o mapeamento é como realizar o cálculo de produtos escalares entre os dados no espaço de características, pois tem-se sempre $\Phi(x_i) \cdot \Phi(x_j)$ para dois dados x_i e x_j em conjunto. Isso é obtido com o uso de funções denominadas Kernels.

Um Kernel K é uma função que recebe dois pontos x_i e x_j do espaço de entradas e computa o produto escalar desses dados no espaço de características. Tem-se então:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j). \quad (26)$$

Para o mapeamento apresentado na equação (21) e dois dados $\mathbf{x}_i = (x_{1i}, x_{2i})$ e $\mathbf{x}_j = (x_{1j}, x_{2j})$ em \mathbb{R}^2 , por exemplo, o Kernel é dado por

$$K(\mathbf{x}_i, \mathbf{x}_j) = (x_{1i}^2, \sqrt{2}x_{1i}x_{2i}, x_{2i}^2) \cdot (x_{1j}^2, \sqrt{2}x_{1j}x_{2j}, x_{2j}^2) = (\mathbf{x}_i, \mathbf{x}_j)^2. \quad (27)$$

É comum empregar a função Kernel sem conhecer o mapeamento Φ , que é gerado implicitamente. A utilidade dos Kernels está, portanto, na simplicidade de seu cálculo e em sua capacidade de representar espaços abstratos.

Para garantir a convexidade do problema de otimização formulado na Equação (23) e também, que o Kernel represente mapeamentos nos quais seja possível o cálculo de produtos escalares, conforme a Equação (26), utiliza-se funções Kernel que seguem as condições estabelecidas pelo teorema de Mercer.

De forma simplificada, um Kernel que satisfaz as condições de Mercer é caracterizado por dar origem a matrizes positivas semi-definidas \mathbf{K} , em que cada elemento K_{ij} é definido por $K_{ij} = (\mathbf{x}_i, \mathbf{x}_j)$, para todo $i, j = 1, \dots, n$.

Alguns dos Kernels mais utilizados na prática são os Polinomiais, os Gaussianos ou RBF (*Radial-Basis Function*) e os Sigmoidais, listados na Tabela 1 - Kernels mais utilizados.

Tabela 1 - Kernels mais utilizados

Tipo de Kernel	Função $K(\mathbf{x}_i, \mathbf{x}_j)$	Parâmetros
Polinomial	$(\delta (\mathbf{x}_i \cdot \mathbf{x}_j) + \kappa)^d$	δ, κ e d
Gaussiano	$\exp(-\sigma \ \mathbf{x}_i - \mathbf{x}_j\ ^2)$	σ
Sigmoidal	$\tanh(\delta (\mathbf{x}_i \cdot \mathbf{x}_j) + \kappa)$	δ e κ

Fonte: Lorena (2011).

Cada um apresenta parâmetros que devem ser determinados pelo usuário, indicados também na Tabela 1. O Kernel Sigmoidal, em particular, satisfaz as

condições de Mercer apenas para alguns valores de δ e κ . Os Kernels Polinomiais com $d = 1$ também são denominados lineares.

2.6. REDES NEURAIIS

A Rede Neural Artificial (RNA) foi proposta pela primeira vez na década de 1940 (PITTS E MCCULLOCH, 1947), e sua ideia é simular o sistema do cérebro humano para resolver problemas de aprendizagem (ZHAO *et al.*, 2018). MITCHELL *et al.* (1997) descreveram de forma semelhante uma rede neural artificial como sendo construída em um conjunto de unidades simples interconectadas, onde cada unidade recebe um número como entrada.

Cada número de entrada vem da saída de outras unidades, produzindo um valor de saída. Essa descrição corresponde à composição da rede neural do cérebro humano, onde cada unidade imita um neurônio. Neurônios artificiais no RNA terão muitas entradas e produzirão uma saída, e cada neurônio está conectado entre si de maneira hierárquica (SHARMA *et al.*, 2012). Cada neurônio gera ativações com base nas conexões ponderadas do ambiente ou outros neurônios, criando uma série de ativações para trazer os dados de entrada da camada inicial para o valor de saída desejado na camada final (SCHMIDHUBER, 2015).


Nas décadas de 1980 e 1990, com a introdução do algoritmo de *backpropagation*, a popularidade das redes neurais artificiais aumentou; mas devido aos problemas de *overfitting*, falta de dados de treinamento, poder de computação limitado e baixo desempenho geral, o interesse da comunidade de pesquisa neste campo diminuiu.

Com o desenvolvimento de novas tecnologias, como: evolução das (CPUs), desenvolvimento de unidade gráfica mais potentes (GPU), grandes conjuntos de dados e desenvolvimento significativo de projetos de rede (Krizhevsky *et al.*, 2012), as redes neurais artificiais tornaram-se novamente atrativa para as pesquisas voltadas para o *machine learning* (ZHAO *et al.*, 2018).

O modelo Perceptron foi desenvolvido pelo cientista Frank Rosenblatt nas décadas de 1950 e 1960 e foi inspirado no trabalho anterior de Warren McCulloch e Walter Pitts. Hoje, outros modelos que usam neurônios artificiais são mais comuns,

mas o Perceptron tem um bom entendimento de como as redes neurais funcionam matematicamente, o que é uma boa introdução. O perceptron é um modelo matemático que recebe múltiplas entradas x_1 , x_2 , etc., e produz uma única saída binária.

Figura 5 – Perceptron




Fonte: Nielsen (2015).

Uma rede neural consiste em três camadas principais (grupos) de neurônios (unidades): entrada, oculta e saída. A camada de entrada é onde os dados são inicialmente inseridos. Em uma rede neural, a camada oculta está localizada entre a entrada e a saída do algoritmo, onde a função aplica pesos à entrada e a direciona à saída por meio da função de ativação. Em suma, a camada oculta realiza uma transformação não linear na entrada inserida na rede. As camadas ocultas variam de acordo com a função da rede neural e, da mesma forma, essas camadas também podem variar de acordo com seus pesos associados (BABA *et al.*, 2013). A Figura 6 representa um esquema de uma rede neural básica.

Existem dois tipos principais de redes neurais. As "redes *feedforward*" (também conhecidas como "redes não repetitivas") permitem que a ativação prossiga em uma única direção, ou seja, da camada de entrada para a saída. Esse tipo de rede é muito simples e geralmente é usado na área de reconhecimento de padrões. O segundo tipo é a "rede recorrente" ou "rede de feedback". Nesse tipo, a ativação pode se propagar em duas direções, criando um loop dentro da rede (SHARMA *et al.*, 2012).

Figura 6 - Composição de redes de múltiplas camadas



Fonte: Nielsen (2015).

O processo de treinamento de uma rede neural (por exemplo, para tarefas de classificação) é projetado para ensinar o modelo a receber entrada e distribuir corretamente a saída necessária. Deve haver um algoritmo que ajude a definir os pesos e 'bias' de todos os neurônios da rede, para que durante o processo de aprendizagem a saída da rede comece a se aproximar da previsão desejada com base na entrada. Uma "função de custo" (também chamada de "função de perda") é criada para calcular o progresso do aprendizado com base nas entradas, pesos, desvios e saídas necessárias. A "função de custo quadrático" (também conhecida como "erro quadrático médio") é uma função de perda popular. Quanto menor for o valor calculado pela função de custo, mais próximo a saída do modelo será da previsão. O algoritmo que utiliza parâmetros (pesos e "biases") e minimiza o valor do custo é denominado "*Gradient Descent*" (NIELSEN, 2015).


O algoritmo de "*backpropagation*" foi introduzido para calcular o gradiente do custo da função. Embora o algoritmo tenha sido proposto pela primeira vez em 1970, ele ainda é uma parte essencial do processo de aprendizagem da rede neural; tem o objetivo de calcular a derivada parcial da função de custo com base nos pesos e desvios da rede neural. Em outras palavras, ele precisa encontrar a mudança do erro

de acordo com a mudança do parâmetro; por exemplo, aumentar ou diminuir o valor do peso (NIELSEN, 2015).

A rede multicamadas contém uma "superfície de erro" que pode ter vários "mínimos locais", ou seja, a área onde o erro é menor, mas não necessariamente o mínimo global no espaço de parâmetros. O algoritmo de *backpropagation* usando o *Gradient Descent* procura os parâmetros espaciais pelo "erro" global mínimo, que corresponde ao menor erro que o algoritmo *Gradient Descent* possa achar nos mínimos locais. Entretanto, o *Gradient Descent* não garante achar o erro mínimo global (melhor mínimo local), uma vez que este pode ficar preso entre mínimos locais (Mitchell *et al.*, 1997).

Ao treinar uma rede neural, o "problema de generalização" é um dos desafios mais comuns. Uma rede com boa generalização alcançará bons resultados tanto na forma da situação (dados de treinamento) quanto em uma nova situação (novos dados). O conceito é reunir apenas a quantidade necessária de conhecimento dos dados; nem muito (*overfitting*) nem muito pouco (*underfitting*), como é descrito na Figura 7.

Figura 7 - Exemplo de dados Under Fit, Apropriado, Over Fit



Fonte: Patterson e Gibson (2017).

A principal estratégia para alcançar bons níveis de generalização é encontrar o modelo mais simples possível que represente os dados. Reduzir a complexidade do modelo também reduz o número de erros. Existem métodos para ajudar a obter uma boa generalização do modelo como o "*Early Stopping*", que visa interromper o treinamento antes que o *Gradient Descent* encontre o erro mínimo global. Isso é feito

não usando todos os pesos. Consequentemente, isso diminui a complexidade do modelo. Se o número de iterações for muito alto, mais dos pesos serão ajustados até que o modelo se ajuste aos dados de treinamento nos mínimos detalhes e, então, ele pode não entender os novos dados. Outra técnica é a “Regularização”. Este método visa penalizar a complexidade do modelo, controlando os valores dos pesos para produzir funções “mais suaves”. É semelhante a reduzir o número de neurônios na rede, uma vez que minimiza o tamanho das inclinações na função que tende a super ajustar os dados (HAGAN *et al.*, 1996).

2.6.1. APRENDIZAGEM PROFUNDA

O *Deep Learning* é um subcampo do *Machine learning* composto por algoritmos que podem aprender em vários níveis de representação e estabelecer relações mais complexas entre os dados (DENG *et al.*, 2014). Sua principal característica é que os extratores de recursos aprendem automaticamente por meio de dados no processo de aprendizagem geral (LECUN *et al.*, 2015).

De acordo com Lecun *et al.* (2015), as técnicas tradicionais de aprendizado de máquina têm capacidade limitada de processar dados em um formato mais natural. Nesse caso, os dados precisam ser processados e alimentados ou no algoritmo de uma forma que corresponda exatamente aos requisitos computacionais, o que requer um projeto cuidadoso de extração de recursos para que os dados brutos originais possam ser transformados em um conjunto de recursos importantes.

O aprendizado profundo permite que os dados sejam inseridos na rede projetada em um formato mais natural, o que detecta automaticamente a representação dos dados relacionados, como classificação e detecção de tarefas. O processo de cálculo é acumulado em várias camadas e cada camada subsequente torna a representação dos dados mais abstrata. Esta técnica permite que o modelo aprenda funções complexas que podem amplificar a relevância de recursos importantes, ao mesmo tempo que suprime essas funções insignificantes (LECUN *et al.*, 2015).

Com o advento do *Deep Learning*, o desenvolvimento de novos modelos pode agora ter deslocado esforços para buscar um melhor design de arquitetura de rede,

em vez de gastar este esforço procurando por uma boa representação de recursos (LIU *et al.*, 2018).

De acordo com Liu *et al.*, (2018), nos últimos anos o *Deep Learning* promoveu um progresso significativo em várias aplicações, como reconhecimento visual, detecção de objetos, reconhecimento de fala, processamento de linguagem natural, análise de imagens médicas, descoberta de medicamentos e genômica. O desenvolvimento em evolução na região é principalmente suportado por poderosos recursos de computação (como GPU) e a disponibilidade de conjuntos de dados em grande escala, que são essenciais para o treinamento de modelos de aprendizado profundo. O aumento contínuo no poder de processamento traz viabilidade para o tempo de treinamento, enquanto permite que o conjunto de dados alimente dados de treinamento mais complexos e aumenta a variedade e a quantidade entre as amostras.

2.6.2. REDES NEURAIS CONVOLUCIONAIS

Um conjunto de tecnologias relacionadas ao aprendizado de máquina, encontram-se os algoritmos baseados em aprendizado profundo (CHEVTCHENKO, 2018). Com o desenvolvimento da tecnologia de processamento gráfico (GPU) a popularidade desses algoritmos aumentou significativamente, pois à medida que os recursos aumentam, o tempo de treinamento desses algoritmos será reduzido (SCHMIDHUBER, 2015). Dessa forma, a precisão da previsão é aprimorada, o que permite que algoritmos baseados em aprendizado profundo superem as técnicas tradicionais de aprendizado de máquina em problemas de alta relevância (SCHMIDHUBER, 2015).

Rede Neural Convolucional (CNN) é uma tecnologia que pertence a um subconjunto de algoritmos baseados em aprendizado profundo. Esses algoritmos destacam a possibilidade de instanciar múltiplas camadas para entender objetos de entrada de vários níveis de representação.

A CNN possui duas características muito importantes que o tornam fácil de treinar e tem forte capacidade de generalização (SCHMIDHUBER, 2015). Portanto,

esses algoritmos não contam com a etapa de implementação de extração de recursos relacionados ao problema a ser resolvido (CHEVTCHENKO, 2018).

Convolutional Neural Networks (CNN), também conhecida como Redes Neurais Convolucionais (ConvNets), são redes relacionadas à maioria dos trabalhos relacionados à visão computacional (REN *et al.* 2015; SZEGEDY *et al.*, 2016; REDMON, 2016; FARHADI, 2016 e HUANG *et al.*, 2017).

Para ZHAO *et al.* (2018), a CNN é o modelo mais representativo em *Deep Learning*. De acordo com SZEGEDY *et al.* (2015), o CNN também é usado em muitas outras tarefas específicas, como detecção de alvo, segmentação, estimador de pose, classificação de vídeo, rastreamento de alvo e super resolução.

Goodfellow *et al.* (2016) explicaram que a CNN é uma rede neural com uma ou mais camadas aplicando uma operação matemática chamada "convolução", em vez de uma matriz de multiplicação padrão das redes neurais.

A CNN é composta por uma combinação de camadas específicas da rede neural, geralmente formadas por três estágios principais: convolução, função de ativação não linear e função de fusão. A camada convolucional aplica o filtro convolucional (kernel) à imagem na janela e gera uma nova imagem (mapa de funções), cujo tamanho é ligeiramente reduzido por padrão e os recursos detectados serão aumentados. No segundo estágio, cada ativação linear gerada na convolução será afetada por uma função de ativação não linear, como uma unidade linear retificada (ReLU). Ao introduzir a não linearidade no modelo, um melhor gradiente de propagação pode ser alcançado. A última etapa é resumir estatisticamente os recursos mais relevantes com base nas saídas vizinhas da camada anterior. Por exemplo, a camada "pesquisa máxima" resulta no valor máximo determinado pela janela na saída anterior (GOODFELLOW *et al.*, 2016).

2.6.3. TRANSFER LEARNING

De acordo com Pan e Yang (2010), a ideia principal da aprendizagem por transferência é usar o conhecimento que foi adquirido em uma área específica e, então, aplicar esse conhecimento para resolver problemas em diferentes áreas. Este

processo de aprendizagem é frequentemente mais rápido do que acumular conhecimento do zero.

Pan e Yang (2010) explicam que para algoritmos de aprendizado de máquina, o conhecimento extraído de dados de treinamento em um determinado domínio não se limita a ser aplicado apenas no mesmo espaço de recursos específico. Além disso, ele não precisa estar na mesma distribuição para permitir que o conhecimento seja reutilizado para outras aplicações. Em algumas situações, ao resolver problemas, geralmente não há dados suficientes no processo de treinamento. Ao mesmo tempo, outros campos geralmente têm dados abundantes, que diferem apenas na distribuição de dados e conjuntos de recursos (JUNLIN *et al.*, 2016).

No campo do aprendizado de máquina, o aprendizado por transferência pode ser definido como o processo de aplicação do ajuste fino e reutilização de uma rede neural pré-treinada em um domínio diferente da rede neural preparada originalmente. Um dos benefícios de usar a aprendizagem por transferência é que o processo de ajuste fino é muito mais rápido do que treinar e reutilizar modelos do zero. Ao treinar com um grande conjunto de dados composto de grandes diferenças dentro das categorias, os pesos geralmente são de alta qualidade, como um conjunto de dados contendo 1.000 categorias e 1,2 milhão de imagens.


Provas práticas dos benefícios da aprendizagem por transferência podem ser facilmente obtidas em experimentos públicos, como o "TensorFlow for Poets" 3, em que o modelo "Inception v3" (Szegedy *et al.*, 2016) pré-treinado pela ImageNet (Arquitetura CNN), recebeu um refinamento para a tarefa de classificação de flores, estando em um domínio diferente para qual o algoritmo foi treinado inicialmente.

2.6.4. YOLO

Yolo é um sistema de detecção de objetos em tempo real, conhecido por ser rápido e preciso. É elaborado como um framework de detecção de estágio único, correspondendo a um pipeline unificado para o processo de treinamento e detecção, onde apenas uma rede faz todo o trabalho. Yolo significa "*you only look once*" (você olha apenas uma vez), referindo-se ao fato de que ele processa a imagem inteira uma única vez, gerando as previsões do objeto. A Figura 8 mostra um exemplo de detecção

que pode ser feita, demonstrando as classes encontradas em uma foto com carro, cachorro e bicicleta.

Figura 8 - Exemplos de Detecção

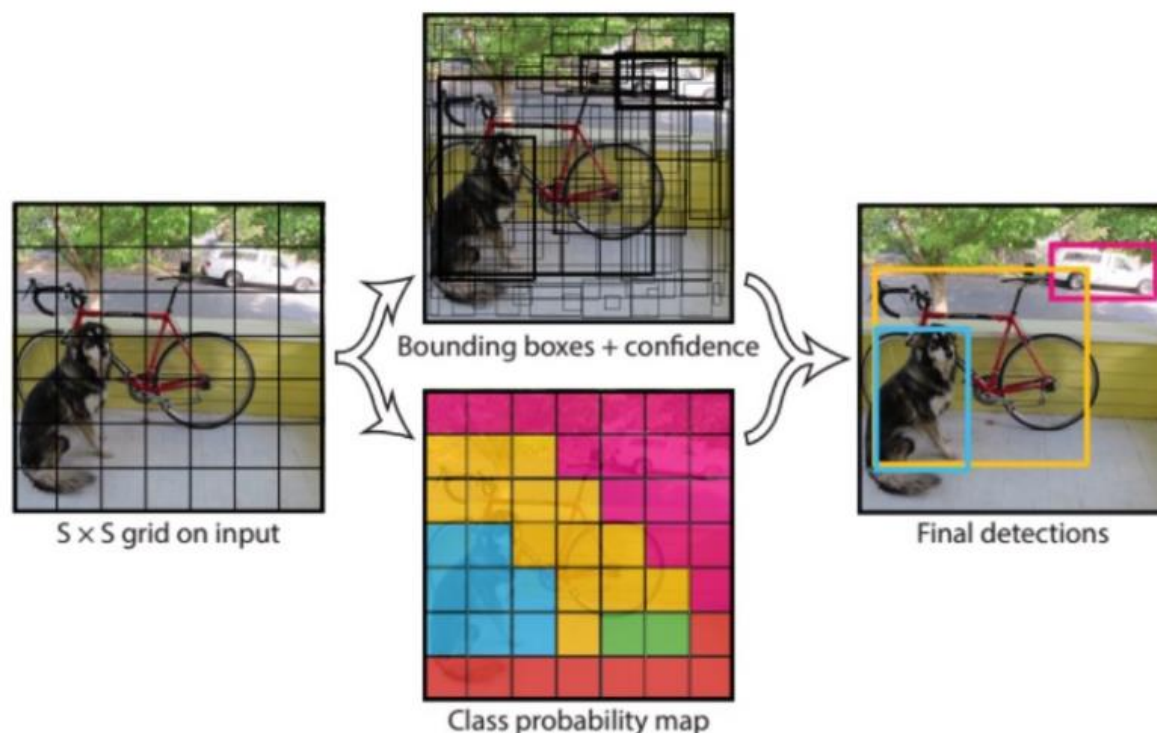


Fonte: <https://pjreddie.com/darknet/yolo/> Redmon e Farhadi (2018).

O Yolo foi criado pensando nas aplicações que requerem baixa latência de processamento, como veículos autônomos e robótica. De acordo com Redmon e Farhadi (2016), o YOLOv2 (segunda versão do Yolo) alcança resultados competitivos no desafio ImageNet (krizhevsky *et al.*, 2012) exigindo apenas 8,52 bilhões de operações em comparação com 30,69 bilhões do VGG16 (SIMONYAN e ZISSERMAN, 2014), que era utilizado por concorrentes diretos, na época, como o *faster R-CNN* (ren *et al.*, 2015). Yolo é rápido porque prevê um grande número de caixas delimitadoras, todas ao mesmo tempo, com uma única passagem na rede (exemplificado na Figura 9). Yolo está atualmente em sua quarta versão, mas as ideias gerais das quatro versões são semelhantes. Yolo funciona dividindo a imagem fornecida em uma grade de células. Há um número fixo de “caixas de âncora” para cada célula, que corresponde a formas de objeto pré-definidas previamente calculadas de acordo com os objetos gerais do conjunto de dados. No YOLOv2 (segunda versão), a grade padrão é 13×13 correspondendo a 169 células, onde cada

célula possui cinco âncoras, totalizando 845 previsões de caixa delimitadora possíveis. A caixa delimitadora é definida como duas coordenadas relativas à matriz da imagem correspondendo à posição central do objeto (“x” e “y”) e as duas dimensões de largura (“w”) e altura (“h”). Células e âncoras, em tais regiões, irão prever objetos em áreas específicas da imagem. Cada caixa delimitadora será acompanhada por uma “pontuação de objetividade” que definirá o grau de confiança do modelo em relação à caixa delimitadora que contém um objeto. Além disso, para cada classe de objeto possível, haverá uma pontuação de probabilidade independente, que juntas devem somar 100%. A função de perda na rede leva em consideração a pontuação de objetividade, a classificação das categorias de objetos e a regressão das coordenadas/dimensões da caixa delimitadora. A ideia geral é ilustrada na Figura 9.

Figura 9 - Esquema de predição



Fonte: <https://towardsdatascience.com/yolo-you-only-look-once-real-time-object-detection-explained-492dc9230006/> Manish Chablani (2017).

O Yolo filtra as previsões definindo uma pontuação de confiança mínima (limite) que é definida por padrão em 30%. Além disso, durante o treinamento, o algoritmo de “supressão não máxima” é aplicado para remover previsões redundantes. As previsões que correspondem ao mesmo objeto de verdade básica serão comparadas e apenas aquelas com a maior confiança serão mantidas. Para cada uma das três versões do YOLO, os autores também lançam a respectiva variante “YOLOtiny”. Esta versão é muito menor em comparação com as padrão e se concentra em ambientes restritos. Apesar de ser uma rede mais rasa, consegue bons resultados (metade da versão padrão) enquanto mais de 10 vezes mais rápida, ou seja, cerca de 220 frames por segundo. Assim, as variantes YOLO-tiny têm sido frequentemente utilizadas em outras aplicações (por exemplo, OCR e biometria) com o objetivo de obter um melhor equilíbrio entre velocidade e precisão (BEZERRA *et al.*, 2018; LAROCA *et al.*, 2019). Todas as versões do YOLO são implementadas com o framework Darknet, escrito nas linguagens de programação C e CUDA, sendo gratuitas e de código aberto.

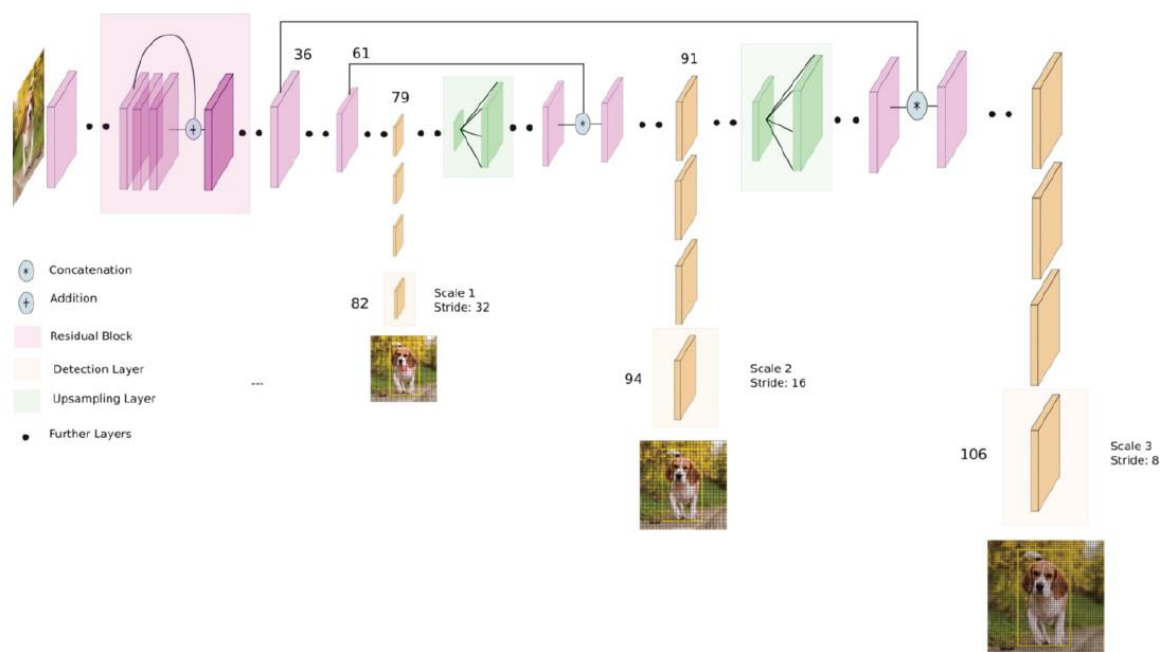
2.6.4.1. YOLOV3

No ano de 2018, Redmon e Farhadi lançaram o YOLOv3 com uma rede composta por 106 camadas (Figura 10), 53 para o *backbone* (“*darknet-53*”) e outras 53 para a tarefa de detecção de objetos, ainda sendo uma rede neural totalmente convolucional. Em comparação com YOLOv2, os autores aplicaram algumas alterações:

- A previsão softmax é substituída pelo classificador logístico independente com funções binárias de perda cruzada. Tal mudança possibilitou enfrentar domínios mais complexos com a classificação multi-rótulo, ou seja, um objeto pode ser anexado a mais de uma classe. Por exemplo, “árvore” e “pinheiro”.
- Três escalas diferentes são agora previstas, para objetos de pequena, média e grande escala. Esta abordagem melhora a precisão da fraqueza conhecida do YOLO relacionada à detecção de pequenos objetos. Para cada escala, há uma grade: 13×13 para objetos grandes, 26×26 para objetos médios e 52×52 para pequenos.

- Em vez de 5 âncoras por célula, a quantidade é aumentada para 9, onde há 3 para cada escala. Enquanto YOLOv2 pode prever 845 caixas delimitadoras, com esta nova configuração YOLOv3 pode prever 10.647.
- Devido ao aumento de camadas na rede, consequentemente, YOLOv3 tornou-se mais lento, mas ainda mais rápido que os concorrentes líderes.
- A nova arquitetura de rede inclui “pular camadas de conexão”, que apresenta um comportamento semelhante às redes residuais.

Figura 10 - Arquitetura YOLOv3



Fonte: <https://towardsdatascience.com/yolo-v3-object-detection-53fb7d3bfe6b> Ayoosh Kathuria (2018).

O YOLOv3 foi avaliado na Tarefa de Detecção COCO (dataset de imagens já categorizados usado para comparação de modelos) para duas métricas diferentes: Precisão Média Média (mAP) - 70 correspondendo a uma métrica de precisão mais rígida e mAP-50 como sendo mais tolerante a qualidades de detecção mais baixas que são convencionais na literatura. No *benchmark* do mAP-50, o YOLOv3 alcançou resultados semelhantes aos concorrentes como RetinaNet (LIN *et al.*, 2017) e DSSD (FU *et al.*, 2017), embora seja mais rápido. No entanto, no benchmark que requer uma

qualidade de previsão mais alta (mAP-70), o YOLO tem uma diminuição significativa na precisão.


2.7. CORRELAÇÃO DE IMAGEM DIGITAL

De acordo com Scuri (2002), computação gráfica contém basicamente dois tipos de informações: as visuais e as descritivas. As informações visuais podem ser exemplificadas através de imagens de uma televisão, ou seja, como a imagem é vista. As informações descritivas são modelos matemáticos que representam o objeto visualizado. Já a área de processamento de imagens contempla as operações que são realizadas sobre imagens e que resultam em imagens.

O processo de digitalização é realizado pela discretização de uma imagem, isto é, transforma uma imagem contínua em uma imagem discreta através de uma função real, do qual $f(x_1, x_2): \mathbb{Z}^+ \rightarrow \mathbb{R}^+$.

Segundo Pesco e Bortolossi (2013), imagens vistas em fotografias na internet são exemplos de imagens digitais; estas imagens podem ser representadas por matrizes como o exemplo da Figura 11, que é uma matriz 35×35 , onde os elementos, que são números 0 e 1, representam a cor de cada pixel, no qual o número 0 representa a cor preta e o número 1 representa a cor branca.

Figura 11 - Representação matricial de imagem binária



Fonte: Pesco e Bortolossi (2013).

Imagens em escala de cinza também podem ser representadas por matrizes, no qual cada elemento da matriz representa a intensidade do pixel correspondente. Já imagens coloridas podem ser representadas por três matrizes, no qual cada matriz representa a quantidade de vermelho, verde e azul que compõem a imagem. Este sistema de cores é conhecido como RGB (*Red*, *Green* e *Blue*). Cada elemento das matrizes contém números inteiros entre 0 e 255 que determinam a intensidade de cada pixel. Por exemplo, a inversão da matriz de luminosidade (Figura 12).

Figura 12 - Processamento Digital de Imagem, Inversão de matriz de luminosidade 5x5

$$\begin{bmatrix} 0,2471 & 0,1882 & 0,0941 & 0,6157 & 0,2588 \\ 0,6157 & 0,5216 & 0,5373 & 0,6824 & 0,1882 \\ 0,1098 & 0,2118 & 0,4824 & 0,2902 & 0 \\ 0,3059 & 0,7804 & 0,1922 & 0,5020 & 0,1843 \\ 0,0549 & 0,3059 & 0,1098 & 0,6118 & 0,2549 \end{bmatrix} \Rightarrow \begin{bmatrix} 0,0549 & 0,3059 & 0,1098 & 0,6118 & 0,2549 \\ 0,3059 & 0,7804 & 0,1922 & 0,5020 & 0,1843 \\ 0,1098 & 0,2118 & 0,4824 & 0,2902 & 0 \\ 0,6157 & 0,5216 & 0,5373 & 0,6824 & 0,1882 \\ 0,2471 & 0,1882 & 0,0941 & 0,6157 & 0,2588 \end{bmatrix}$$

Fonte: Ozelo (2010).

2.8. TÉCNICA DE CORRELAÇÃO DE IMAGENS DIGITAIS (DIC)

A medição é essencial a quase todos os aspectos dos empreendimentos humanos, pois são necessárias para as atividades de controle da produção, avaliações do meio ambiente, saúde, segurança, qualidade de materiais, entre outros vários exemplos (CHU *et al.*, 1985). Tendo em vista a essencialidade da medição, o desenvolvimento de técnicas para obtenção de distância tem sua justificativa. Técnicas de medições de deslocamento foram e continuam sendo desenvolvidas, como a interferometria holográfica (GOTTENBERG, 1968), interferometria Moiré (POST, 1983) e Interferometria Speckle (WANG, *et al.*, 1993); entretanto, técnicas interferométricas requerem um nível de estabilidade que torna o processo demasiadamente difícil e demorado.

A Correlação Digital de Imagens (PETERS, *et al.*, 1983), tornou-se uma possível solução, pois não precisa de contato do objeto a ser medido. A técnica consiste em um processamento digital de imagem que tem como objetivo determinar os campos de deslocamento de deformação de um corpo.

Inicialmente proposta por Sutton *et al.* (1983), a técnica consiste em deixar um padrão de pontos sobre um objeto, que será gravado por uma câmera de vídeo durante o processo de aplicação de força/deformação. Os padrões de pontos são identificados pelos diferentes níveis de intensidade de luz através da digitalização da imagem, os quais serão correlacionados por um algoritmo para descobrir as diferenças entre ambas.

A eficiência e precisão do DIC depende do algoritmo de reconhecimento de padrões entre imagens quase semelhantes. Já em 1989 a eficiência computacional do método foi aprimorada por Bruck, utilizando o algoritmo melhorado pelo método Newton Raphson, com correção diferencial parcial. Sua metodologia assume que a deformação local era uniforme; assim, o deslocamento foi representado por dois deslocamentos e quatro gradientes, fornecendo uma convergência maior na busca pelo mínimo local com alta precisão. Apesar da grande melhora na velocidade de convergência, o método de Newton-Raphson com correção diferencial parcial ainda


sofre com o consumo significativo de tempo de computação na detecção do mínimo local.

Hung e Voloshin (2003), produziram um algoritmo de busca simples, que permitiu uma abordagem de correlação de imagens digitais mais aplicável para uso prático. O algoritmo proposto usa uma pesquisa precisa (pixel por pixel) no nível do pixel com área fixa. A precisão dos resultados experimentais deste algoritmo proposto não foi superior ao método de Newton-Raphson; entretanto, os resultados experimentais mostram que a velocidade de detecção é aumentada o suficiente, enquanto a degradação na precisão era aceitável para uso prático.

2.9. HISTOGRAMA DE CORES


Com a matriz da imagem é possível realizar um processamento digital de imagem para produzir um histograma de cores que foca apenas na proporção dos números de diferentes tipos de cores, independentemente da localização. Eles mostram a distribuição estatística das cores e o tom essencial de uma imagem. O histograma pode ser representado como uma função 1-D, onde a variável independente é o valor de cinza e a variável dependente é o número de pixels com esse nível de cor. O histograma descreve uma característica específica da imagem como, a população de níveis de cinza (Figura 13) representado na (Figura 14).

Figura 13 - Lake (tamanho 5306 x 3770)



Fonte: fineartamerica.com (2017)

Figura 14 - Histograma do Lake em escala de cinza



Fonte: Próprio autor

Historicamente, o histograma de cores tem sido usado pela comunidade de visão computacional no entendimento de imagens. Geralmente, a cor é considerada uma propriedade importante dos objetos e é usada para segmentação e classificação. O histograma também pode ser representado no formato de vetor que possui basicamente o número de ocorrência de cada cor, descrito por

$$d_i = (i_1, \dots, i_{255}) . \quad (28)$$

Sendo d_i = vetor de característica e i_1, \dots, i_{255} = vetor de ocorrência de cores.

2.10. CORRELAÇÃO DIGITAL DE IMAGENS APLICADO À ENGENHARIA

As aplicações do uso de correlação de imagem digital foram expandidas para aplicações dentro da engenharia. Hild e Roux (2006) extraíram campos de deslocamento de fotos tiradas em instantes diferentes durante um experimento no qual são criados procedimentos de identificação de deslocamento de subpixel.

Giancane *et al.* (2010) analisaram os fenômenos de danos por fadiga em laminados GFRC sob carga de fadiga elástica empregando amostras entalhadas e livres de entalhes. A análise de danos com base na técnica DIC óptica foi realizada

para detectar as áreas danificadas na superfície da amostra e seguir os mecanismos de falha durante a vida útil. Ainda, Marion *et al.* (2010) apresentaram uma abordagem que é baseada na análise de medidas de campo de deslocamento por correlação de imagem digital (DIC) durante testes de fadiga de baixo ciclo; nesta condição uma ferramenta de filtragem específica é apresentada para minimizar os erros quando uma operação derivada é executada para o cálculo da deformação.

Já para a área da engenharia civil, Malesa *et al.* (2010) criaram uma adaptação da técnica DIC para monitoramento de estruturas. É descrito um conceito geral do complexo sistema de monitoramento automático no qual o sensor DIC desempenha um papel importante. Como exemplo de aplicação são apresentadas medidas de uma ponte ferroviária em Nieporet (Polônia). Os resultados experimentais são comparados com deslocamentos de um modelo FEM da ponte.

Caminero *et al.* (2013) estudaram para a área de materiais compósitos a avaliação do processo de danos em amostras entalhadas (orifícios abertos) sob carga de tração uniaxial. Técnicas de Correlação Digital de Imagem (DIC), bidimensional (2D) e tridimensional (3D), foram empregadas para obter medições de deformação superficial de campo completo em placas compostas de carbono-fibra/epóxi M21/T700 com diferentes sequências de empilhamento, na presença de um furo circular aberto. Também para a área de materiais compósitos, Goidescu, *et al.* (2013) apresentaram um trabalho dedicado ao estudo do processo de dano em compósitos laminados reforçados com fibra de carbono. Apresentaram uma abordagem experimental combinando três técnicas de medição óptica. Correlação estéreo da imagem e a termografia por infravermelho, que fornecem respectivamente, os campos cinemático e térmico na superfície dos compósitos, são usadas na gravação ao vivo durante testes de tração no eixo e fora do eixo além da tomografia de raios X que permite uma análise pós-falha dos padrões de degradação no volume dos laminados. Todas essas técnicas são não destrutivas (sem contato) e oferecem uma interessante investigação em campo completo da resposta do material.

O uso da correlação de imagens digital é cada vez mais utilizado e testado, pois, com o avanço tecnológico do processamento computacional é possível atingir resultados com maiores precisões (CAMINERO, 2013).

O baixo custo das análises é um outro fator muito importante, pois assim permitem que empresas que demandam de manutenção constante sejam beneficiadas, além de reduzir o risco de falhas de seus equipamentos. Com o método apresentado essas empresas têm a possibilidade de fazer análise simultânea dos corpos de provas, de forma rápida, sem a necessidade de utilização de ensaios destrutivos e evitando contato com o mensurando (HILD, 2008).

Recentemente, Bataxi (2019), citou que os laminados compostos são suscetíveis a danos por impacto. A detecção de danos depende principalmente da inspeção visual e do C-scan (ensaio de ultrassom não destrutivo), mas esses dois métodos são limitados às habilidades técnicas do inspetor e podem levar a uma falha na detecção ou uma detecção de baixa qualidade. A tecnologia de correlação de imagem digital de campo total (DIC) tem sido gradualmente aplicada à medição de superfícies estruturais. Laminados compostos com vários graus de dano BVI (*Barely Visible Impact Damage*) foram estudados sob condições de tensão e compressão. Os resultados mostram que o método DIC pode capturar as singularidades de deformação na área de dano do laminado. A singularidade da deformação é causada pela quebra da fibra sob carga de tração e empenamento sob carga de compressão.

Man (2020) propôs um método baseado em correlação de imagem digital (DIC) para caracterizar o início e a expansão da delaminação por fadiga tipo I em laminados compostos. O DIC é usado para analisar o campo de deslocamento da borda da amostra DCB (double cantilever beam), e assim determinar a posição da ponta da trinca como a posição onde o deslocamento de abertura converge para zero. Este método foi usado com sucesso para detectar o início de rachaduras (a vida em que a fadiga começa) e para monitorar o crescimento sob os ciclos de fadiga. Comparado com o método baseado em consistência recomendado na norma ASTM, o método baseado em DIC depende da localização real da ponta da trinca e fornece um valor conservador para o início da vida de fadiga.

2.11. MATERIAIS COMPÓSITOS

A atual definição de material compósito entende-se como, dois ou mais componentes macroscopicamente diferenciáveis, que apresentam diferenças nas

propriedades física e química mostrando uma fase descontínua (reforços) e uma fase contínua (matriz), com a filosofia de se obter um material que apresenta melhores propriedades físicas que a de seus elementos separadamente (NETO 2006).

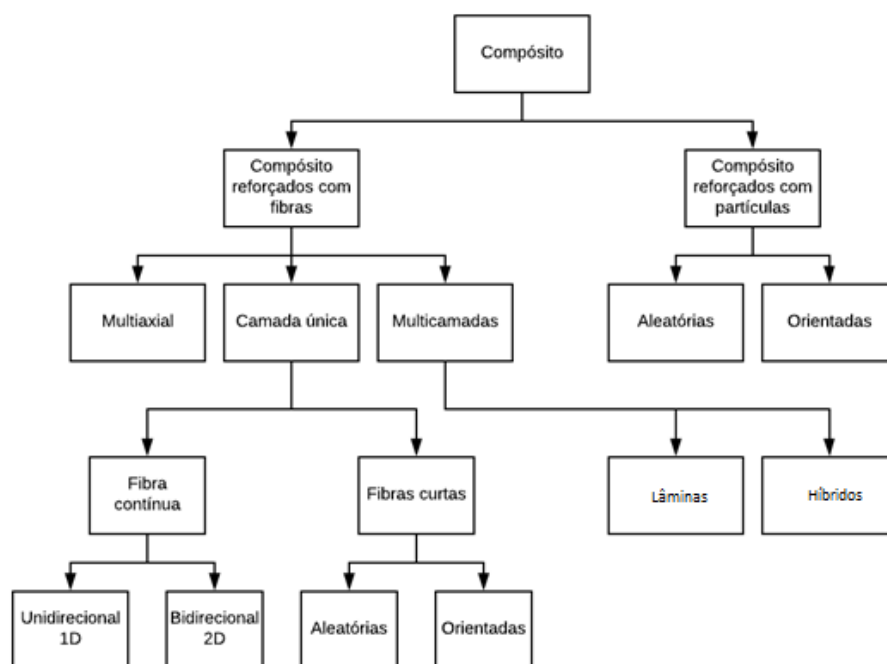
As propriedades dos compósitos estão diretamente ligadas às propriedades dos elementos constituintes do material, assim como sua geometria, concentração ou frações volumétricas, adesão fibra/matriz, disposição das camadas e orientação (MARINUCCI, 2011).

Os materiais compósitos são constituídos por matriz e reforço, no qual a matriz é composta de materiais cerâmicos, metálicos e/ou de polímeros que têm como função dar geometria ao componente fabricado, proteção contra agentes químicos, proteção e posicionamento do reforço, aglutinação e transmissão dos esforços para os reforços, assim permitindo que ambos trabalhem sinergia.

2.11.1. CLASSIFICAÇÃO DE COMPÓSITOS

Os materiais compósitos podem ser classificados de várias maneiras: geometria de orientação dos reforços, sintéticos/naturais, fibrados/particulados, entre outros. Segundo classificação de Neto (2006), os materiais compósitos podem ser divididos conforme Figura 15.

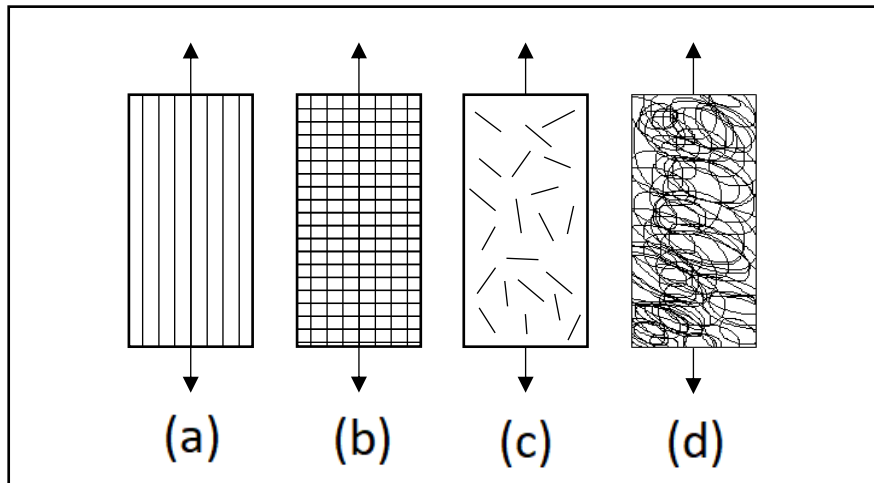
Figura 15 - Classificação de compósitos



Fonte: Neto (2006)

Ainda Segundo Neto (2006), de acordo com a Figura 16 os compósitos podem ser divididos de acordo com seus reforços, sendo fibras e partículas. Com os reforços dispostos em formato de fibra podemos subdividir esta categoria entre feixes paralelos, multicamadas e na forma de camada isolada ou lâminas. Compósitos com reforços multidirecionais têm como base as pré-formas têxteis e constituem um salto tecnológico no sentido de se obter estruturas maciças de grande volume e com propriedades ajustadas à sua aplicação.

Figura 16 - Lâminas com reforços: (a) unidirecional; (b) tecido bidirecional; (c) fibras picadas; (d) manta contínua, submetida a esforços de tração uniaxial longitudinais.




Fonte: Neto (2006)

Os compósitos de camada única são subdivididos em reforços de fibra contínua e curta. Os compósitos de multicamadas podem ser divididos em laminados (único tipo de fibra, orientação de fibra definida ou distinta) e híbridos (dois ou mais tipos de fibras de reforços são utilizados).

Compósitos advindos de fibras contínuas podem ser unidirecionais ou bidirecionais (tecidos); alguns tipos são apresentados na Figura 17.

Figura 17 - Tipos de compósitos



Fonte: Neto (2006)

Segundo Gasparin *et. al.* (2011), levando em conta que a palavra adesão vem do latim “*adhaerere*”, que significa “grudar”, a Figura 18 mostra um diagrama de temas

para descrever os fenômenos envolvidos na palavra adesão onde dois corpos estão unidos.

Figura 18 – Adesão



Fonte: Gasparin (2011)

A interface fibra/matriz comporta-se como o elo entre os materiais constituintes do compósito polimérico, pois transmite os esforços da matriz para o reforço (as fibras) e pode ser caracterizada como a região que está sob a superfície das fibras e em contato com a matriz que as envolve. Tem a função de compatibilizar as diferentes propriedades das fibras e matriz. A norma ASTM D 907 define adesão como forças interfaciais entre duas superfícies que se mantêm unidas devido a forças de valências e ou forças de ancoramento mecânico. Entre os mecanismos responsáveis pela adesão, quatro se destacam: o mecanismo de absorção (adesão de contato), o mecanismo de difusão ao redor da interface, o mecanismo de ancoramento mecânico e o mecanismo de adesão eletrostática. Para se determinar a força de adesão é necessário um ensaio destrutivo de junta, como ocorre nos ensaios de cisalhamento ou de tração, que provocam quebra total ou parcial do sistema (GASPARIN, 2011).

As propriedades mecânicas do compósito estão diretamente relacionadas ao teor de fibras que são incorporadas no material. Quanto maior o teor de fibras, melhor será o desempenho, pois maior será o número de fibras que interceptam cada

microfissura, evitando assim a propagação das mesmas (GARCEZ, 2005). As fibras absorvem partes das tensões internas devido aos esforços imposto à matriz, resultando assim na maioria dos casos, no aumento do módulo de elasticidade e tensão máxima de ruptura do compósito. Os parâmetros, frações volumétricas de fibras (V_f), matriz (V_m) e vazios (V_v), são usados para quantificar os volumes percentuais de cada componente em relação ao volume total do compósito. Os valores de V_f e V_m são controlados dentro de certos limites no processo de fabricação dos compósitos. Normalmente, utiliza-se o valor de vazio menor que de 1% em relação ao volume, pois este tem grande impacto no desempenho mecânico do compósito, influenciando principalmente a resistência à fadiga quando usado em projetos estruturais.

2.11.1.1. MATRIZ POLIMÉRICA

Os compósitos avançados mais comuns são compósitos com matriz polimérica (PMCs) consistindo de um polímero (como, epóxi, poliéster, uretano) reforçado por fibras de diâmetro fino (como, grafite, aramidas, boro). Por exemplo, compósitos de grafite / epóxi são aproximadamente cinco vezes mais fortes que o aço (MOURA, 2005). As razões pelas quais eles são os compósitos mais comuns são o baixo custo, alta resistência e simples fabricação.

2.11.1.2. REFORÇOS

Os reforços de compósitos se apresentam na forma de fibras contínuas, picadas e na forma de partículas. As fibras são elementos dos compósitos estruturais que suportam carregamento mecânico. Grande parte das fibras comerciais são produzidas através de: fiação por fusão, fiação a úmido e fiação a seco (MOURA, 2005).

O uso da fibra como reforços são meios efetivos, uma vez que apresentam baixo número de defeitos em relação a sua forma mássica, pois de acordo com sua redução de espessura o material tende a aproximar sua resistência do valor teórico.

2.11.1.2.1. FIBRAS DE VIDRO

As fibras de vidro são as mais utilizadas nas matrizes poliméricas, devido ao baixo custo e a alta resistência a tração; possuem propriedades isotrópicas em relação seu módulo de elasticidade, mas apresentam baixo módulo de elasticidade, auto abrasividade e baixa resistência à fadiga quando usada em compósitos. A Tabela 2 apresenta algumas propriedades mecânicas de compósitos com fibras de vidro.

Tabela 2 - Propriedades das fibras de vidro

Propriedade	Vidro E	Vidro S	Vidro R
Densidade (g/cm ³)	2.6	2.49	2.55
Módulo de Young	73.0	85.5	86.0
Tensão de rotura (MPa)	3400	4580	4400
Deformação na rotura	4.4	5.3	5.2
Coefficiente de expansão térmica (10 ⁻⁶ /°C)	5.0	2.9	4.0


Fonte: Marinucci (2011)

2.11.2. FALHA EM MATERIAIS COMPÓSITOS

Segundo Marinucci (2011), as propriedades dos compósitos dependem da matéria prima, projeto e análise estrutural a qual leva em consideração aspectos como carga, condição de uso, exposição às condições do meio ambiente, orientação de fibras, sequência de posicionamento das camadas (*stacking sequence*) e polimerização da matriz. Essas condições, além da própria anisotropia que caracteriza o material, torna o estudo de falha a fratura mais complexa se comparado aos metais.

Os compósitos poliméricos compostos por reforço de filamentos contínuos ao apresentarem falha podem ser subdivididos em três tipos: intralaminar; interlaminar e translaminar. Essa classificação, mostra o plano de fratura em relação a microestrutura do material, o que pode ser observado na Figura 19.

Figura 19 - Tipos de falhas em compósitos




Fonte: Marinucci (2011)

Falhas intralaminares (dentro das lâminas) estão orientadas dentro das camadas e tem o mesmo sentido das fibras; falhas interlaminares (entre camadas) estão orientadas no plano paralelo às camadas e tendem a ser dominados por fratura da matriz e separação da fibra da matriz, causando uma das falhas mais presentes nos compósitos, a delaminação; falhas translaminares são orientadas transversalmente ao plano do laminado caracterizado pela quebra das fibras (MARINUCCI, 2011). As falhas interlaminar e translaminar podem ocorrer de segundo o modo I, modo II, modo III e podem ser observadas na Figura 20.

A classificação pelo do tipo de falha é útil, pois se adequa à escolha do método analítico para cada fratura. Falhas interlaminares, que têm como exemplo mais característico a delaminação, são melhores analisadas por microscopia ótica, tendo como um dos objetivos a observação da direção do crescimento da trinca, enquanto que nas falhas translaminares, que produzem a ruptura de fibra, recomenda-se análise por microscopia eletrônica de varredura (MARINUCCI, 2011).

Figura 20 - Modos de falha interlaminar e translaminar



Fonte: Marinucci (2011)

2.11.2.1. FALHAS EM LÂMINAS UNIDIRECIONAIS

Fraturas provocadas por imperfeições do material podem ocorrer tanto na fibra quanto na matriz, com vários modos de falha que podem surgir em função da extensão de uma trinca. Para garantir a integridade e desempenho de lâminas submetidas a carregamentos uniaxiais de acordo com sua finalidade, é necessário compreender os modos de falha que conduzem a fratura em termos da matriz e a fibra, para determinar a resistência de materiais compósitos laminados (MARINUCCI, 2011).

2.11.2.2. TRAÇÃO LONGITUDINAL

Lâminas submetidas a tensões longitudinais podem apresentar pelo menos três características de fraturas:

- Frágil;
- Frágil com arrancamento;
- Frágil com fraturas irregulares e descolamento (*debonding*) e/ou cisalhamento da matriz acompanhadas de arrancamento dos filamentos da matriz.


Lâminas com fração volumétrica de fibra (V_f) abaixo de 40% apresentam uma fratura características de materiais frágeis. Com o aumento da tensão outros filamentos são quebrados, assim, eventualmente uma região atinge um tamanho crítico e a trinca se propaga através da seção provocando a fratura. Quase sempre tal fratura se apresenta de uma forma plana (MARINUCCI, 2011).

Para frações volumétricas entre 40 a 65% exibem fratura característica de material frágil. Lâminas com fração volumétrica de fibra acima de 65% apresentam fratura por descolamento e/ou cisalhamento da matriz, acompanhada de arrancamento dos filamentos e apresentam falha explosiva (MARINUCCI, 2011).

2.11.2.3. TRAÇÃO TRANSVERSAL

Fibras orientadas perpendicularmente à direção do carregamento comportam-se como concentradores de tensão na matriz e na interface, provocando fratura na matriz quando nessa o limite de resistência a tração é atingido (conforme ilustra Figura 21) e descolamento do elemento de reforço, quando o limite de resistência da interface é superado. Normalmente a falha apresenta-se plana e perpendicular à seção transversal do corpo de prova.

Figura 21 - Folhas sobre a seção transversal



Fonte: Adaptado Marinucci (2011)

Para obter materiais compósitos com o objetivo de atender projetos de grandes especificações técnicas, é necessário a combinação de dois ou mais materiais com diferentes características, sejam elas mecânicas, físico-químicas e com diferentes processos de fabricação. Com o aumento da exigência do mercado consumidor torna-se essencial o desenvolvimento de pesquisas voltadas para materiais compósitos com

intuito de atingir melhores propriedades mecânicas: menor peso, resistência à erosão, entre outras propriedades (REZENDE, 2000).

2.12. MONITORAMENTO DE SAÚDE ESTRUTURAL (SHM)

Segundo Farrar e Worden (2006), *Structural Health Monitoring* (SHM) pode ser caracterizado como um conjunto de técnicas utilizadas para identificação de danos de estrutura civil/mecânica de forma contínua, isto é, a observação de uma estrutura ou sistema mecânico ao longo do tempo usando medições periódicas para extrair dados capazes de identificar dano. Uma análise estatística dos dados é realizada para determinar o estado atual da integridade do sistema.

O dano para o SHM consiste em qualquer alteração negativa da resposta dinâmica de uma estrutura; entretanto esta alteração não implica necessariamente na perda total de operação do sistema, mas sim no funcionamento inadequado do mesmo. Com a evolução do dano o sistema se tornará inoperante, ponto no qual seu funcionamento não é mais aceitável para o usuário, o que é definido como falha (FARRAR; WORDEN, 2006).

Historicamente as barragens foram uma das primeiras estruturas a ser obrigatório a aplicação do SHM, impulsionado por um desastre em 1864, onde o rompimento de uma barragem de rejeitos provocou a morte de 254 habitantes na cidade de Sheffield (Inglaterra). O desenvolvimento do SHM foi consolidado mais recentemente pela lei Reservoir Act, criada em 1975, atribuindo ao engenheiro supervisor a responsabilidade do monitoramento contínuo, da manutenção e da interpretação de dados operacionais de barragens. Por ser uma das primeiras técnicas de SHM trouxe bastante experiência e aprendizado, sendo assim expandida para outras estruturas (DETR 2001).

Um dos primeiros passos para SHM aplicado em pontes foi realizado por Carder em 1937, nas pontes Golden Gate e Bay Bridges, em São Francisco; no qual foi elaborado a medição do comportamento dinâmico de vários componentes durante sua construção, para possíveis consequências oriundas de terremotos (BROWNJOHN, 2007).

Mudando para estruturas mais complexas, Smith em 1996, apresentou um estudo onde os componentes dos reatores nucleares eram monitorados para fornecer detalhes críticos a segurança da usina, assim como a medição da resposta estrutural para calibração durante o teste de desempenho (BROWNJOHN, 2007).

Em 2010, Diamanti apresentou um estudo sobre os métodos de inspeções atuais em materiais compósitos aplicados em aeronaves. A técnica baseia-se na varredura das estruturas de múltiplas camadas com a intenção de identificar danos internos nos compósitos (DIAMANTI, 2010).

Há várias maneiras de se organizar um estudo de SHM. Seguindo o modelo apresentando no artigo “*Vibration-based structural damage identification*” (Farrar *et al.*, 2001), o processo pode ser definido pelo paradigma de reconhecimento de padrões, o qual é dividido em quatro etapas:

- Avaliação operacional;
- Aquisição de dados, normalização e limpeza;
- Extração de recursos e condensação de informações;
- Desenvolvimento de modelo estatístico para discriminação de características.

2.12.1. AVALIAÇÃO OPERACIONAL

A avaliação operacional tenta responder a quatro questões relacionadas à implementação da capacidade de identificação de danos.

- Quais são as justificativas de segurança de vida e econômica para realizar o SHM?
- Como os danos são definidos para o sistema que está sendo investigado? Para possibilidades de múltiplos danos, quais casos são os mais preocupantes?
- Quais são as condições, tanto operacionais quanto ambientais, sob as quais o sistema a ser monitorado funciona?
- Quais são as limitações na aquisição de dados no ambiente operacional?

A avaliação operacional define as limitações sobre o que será monitorado e como o monitoramento será realizado. A avaliação adapta o processo de identificação de danos ao sistema que está sendo monitorado.

2.12.2. AQUISIÇÃO DE DADOS, NORMALIZAÇÃO E LIMPEZA

A parte de aquisição de dados do processo SHM envolve a seleção dos métodos de excitação, os tipos de sensores, números e localizações e o hardware de aquisição/armazenamento/transmissão de dados.

Como os dados são medidos em condições variadas, a capacidade de normalizar os dados é muito importante para o processo de identificação de danos. A normalização dos dados é o processo de separar as variações das leituras dos sensores provenientes das variações operacionais e das condições do ambiente.

A limpeza de dados é o processo de aceitar ou rejeitar a seleção de recursos.

2.12.3. EXTRAÇÃO DE RECURSOS E CONDENSAÇÃO DE INFORMAÇÕES

A extração de recursos é o processo de identificar as estruturas sensíveis aos danos (medido pelo sistema). Este processo permite distinguir a estrutura não danificada e a estrutura danificada. As tecnologias de implementação e de diagnósticos de medições necessárias para executar o SHM geram uma grande quantidade de dados; quase todos os procedimentos de extração de recursos usam a compactação de dados.

Para obter uma estimativa precisa da distribuição estatística é necessário a compactação dos danos em vetores de pequenas dimensões.

2.12.4. DESENVOLVIMENTO DE MODELO ESTATÍSTICO PARA DISCRIMINAÇÃO DE CARACTERÍSTICAS

Os algoritmos usados nos desenvolvimentos de modelos estatísticos geralmente têm disponíveis os dados da estrutura danificada e não danificada; os algoritmos de reconhecimento de padrões estatísticos são classificados como aprendizado supervisionado. A classificação de grupos e a análise de regressão também são algoritmos de aprendizados supervisionados. A classe de algoritmos no qual os dados não contêm exemplos de estruturas danificadas são os algoritmos de aprendizados não supervisionados, que, em geral, possuem uma análise de

anomalias aplicada ao SHM. Métodos de aprendizagem supervisionada incluem, resposta de análise de superfície, discriminantes lineares, redes neurais e algoritmos genéticos. Métodos de aprendizado não supervisionados incluem análise de gráficos de controle e métodos de detecção de novidades.

2.12.5. SHM APLICADOS EM MATERIAIS COMPÓSITOS

O uso de compósitos estruturais é predominante na indústria aeroespacial. Seu uso incorpora vários sensores e atuadores para garantir o desempenho ideal das estruturas. Os compósitos oferecem melhores propriedades específicas de rigidez e resistência do que o metal. No entanto, o uso de compostos também leva a novos tipos de modos de falha, como a delaminação.

Kaiser *et al.* (1999) discutiram o uso de sensores e atuadores que estão em funcionamento para realizar o monitoramento dinâmico da condição estrutural. Os autores realizaram vários testes em placas de materiais compósitos não danificados e delaminados para mostrar que a delaminação em compósitos pode ser detectada através da identificação de parâmetros modais.

Chen *et al.* (1997) estudaram uma técnica que pode ser usada para detectar dano dentro de canais C compostos de polímero reforçado com fibra de vidro (GFRP). A técnica consiste em incorporar partículas ferromagnéticas na matriz composta de GFRP. Um campo magnético alternado é então passado sobre o canal composto, o que faz com que as partículas magnéticas vibrem. Um Vibrômetro Laser Doppler registra a vibração resultante do compósito. O dano foi introduzido em algumas das amostras pela adição de delaminações centrais durante o procedimento de lay-up.

Elvin e Leung (1997) analisaram a viabilidade de detectar a delaminação dentro de estruturas de vigas de compósitos usando sensores de fibra ótica. Em seu método, um único sensor de fibra ótica será incorporado dentro da estrutura composta. Um sensor de fibra ótica separado, fora da estrutura, servirá como referência. À medida que o carregamento é aplicado à estrutura de compósito, o comprimento do caminho óptico da fibra incorporada será alterado, o que criará uma mudança de fase entre a saída da fibra incorporada e a fibra de referência. Os autores afirmam que aplicando uma carga pontual móvel à estrutura de compósito, é possível detectar e caracterizar

a delaminação dentro da estrutura. À medida que a carga pontual é movida sobre uma região delaminada, a extensão total da fibra incorporada mudará significativamente. Observando a posição da carga, bem como a magnitude da mudança na extensão total, a posição e a magnitude relativa da delaminação podem ser determinadas. Os autores estudaram a viabilidade desta abordagem, modelando uma viga usando o método dos elementos de contorno (BEM). Com base em sua análise, os autores concluíram que a mudança na extensão total do sensor de fibra óptica dentro da estrutura de compósito poderia, de fato, ser usada para detectar e caracterizar a delaminação.

Maseras-Gutierrez *et al.* (1998) discutiram a detecção de impactos dentro de uma estrutura com materiais compósitos. Os autores instrumentaram um compósito retangular com sensores piezo cerâmicos. O compósito de teste foi então impactado em vários locais. Dados dos sensores foram usados para treinar duas redes neurais perceptron multicamadas (MLP). Essas redes foram usadas para prever a intensidade do impacto e a localização dentro da estrutura de teste.

Staszewski *et al.* (2000) empregaram uma rede neural artificial para estimar a localização e a amplitude do impacto em um painel composto e usaram um algoritmo genético para determinar as localizações ótimas dos sensores. Uma estrutura em forma de caixa composta de canais de alumínio e uma placa de compósito foram usadas como amostra de teste para simular o painel de um avião. Os impactos na placa de compósito foram aplicados na superfície superior, enquanto a superfície inferior foi instrumentada com 17 piezo cerâmicas para registrar dados de deformação. Uma rede neural padrão de perceptron de multicamadas (MLP) treinada com a regra de aprendizado de propagação reversa foi usada para este experimento. As coordenadas x e y do impacto foram identificadas usando o tempo após o impacto da resposta máxima e a magnitude da resposta como entradas para a rede neural.

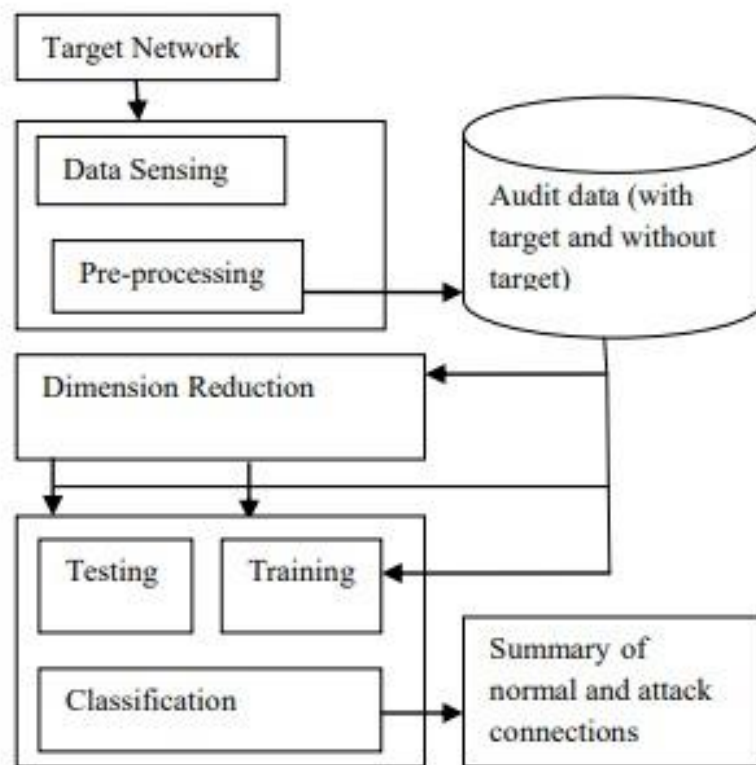
Kessler *et al.* (2002) apresentaram parte de um levantamento experimental e analítico de métodos candidatos para a detecção de danos em materiais compósitos. Mudanças nas frequências e modos naturais foram encontradas usando um vibrômetro laser; modelos de elementos finitos 2-D foram criados para comparação com os resultados experimentais.

Wang e Yuan (2007) investigaram teoricamente e experimentalmente as características de propagação das ondas de *lamb* em compósitos, com ênfase na velocidade de grupo e nas curvas de onda características. Em particular, o estudo experimental focaliza a existência de múltiplos modos de ondas de *lamb* de ordem superior, as quais podem ser observados a partir de sensores piezoelétricos pela excitação de frequências ultrassônicas.

A competição das companhias aéreas torna evidente que a redução de custo será determinante para oferecer serviços melhores para seus consumidores. O monitoramento contínuo aumentará significativamente a segurança operacional, pois as informações adquiridas em tempo real beneficiam o entendimento da mecânica de fraturas de compósitos, melhorando a confiança em seu uso e ampliando suas aplicações. O custo da inspeção é de aproximadamente um terço da compra e operação de estrutura de materiais compósitos. Com a maior competição da indústria de aeronaves é necessário constante pesquisa e desenvolvimentos de novas técnicas com o objetivo de redução de custo; então grandes áreas precisam ser escaneadas rapidamente, sem a necessidade de remoção de componentes individuais, minimizando a interrupção da operação da estrutura (DIAMANTI, 2010). A Figura 22 demonstra um projeto de inteligência artificial para identificação de anomalia de George (2012) utilizando o algoritmo SVM.

Smarsly (2016), relata um método de aprendizado de máquina incorporado para detectar falhas de sensores autônomos e descentralizados em redes de sensores sem fio, facilitando assim o monitoramento de integridade estrutural confiável. Com base em uma rede neural artificial descentralizada, um método de aprendizado de máquina embutido é aplicado para realizar a detecção autônoma de falhas de sensor, que são injetadas nos dados de resposta de aceleração coletados pelo sistema de monitoramento de integridade estrutural do protótipo. Os resultados destacam a capacidade dos métodos de aprendizado de máquina incorporados em detectar falhas de sensor de maneira autônoma de uma maneira descentralizada, melhorando assim a confiabilidade e a precisão do sistema de monitoramento de integridade estrutural.

Figura 22 - Exemplo de uma aplicação de algoritmo de machine learning de detecção de anomalia.



Fonte: George, (2012)

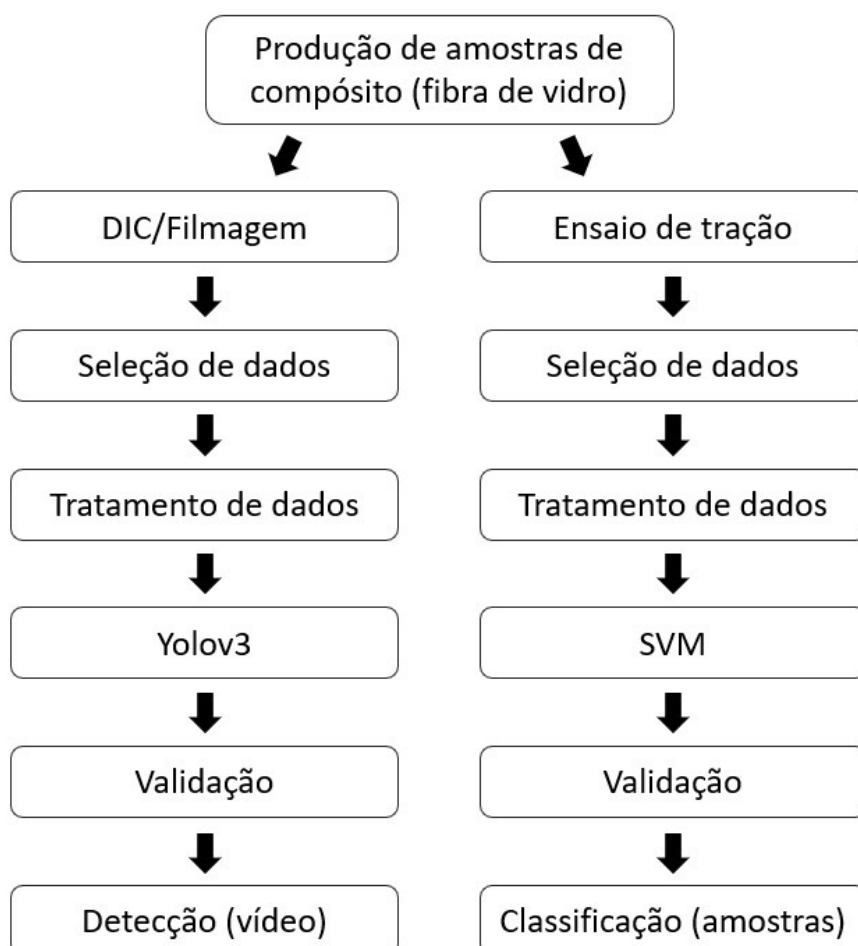
Das *et al.* (2020), faz uma revisão dos materiais usados para a construção de aeronaves, assim como discute uma revisão sobre a eficácia da aplicação de técnicas de ensaios não destrutivos e vários métodos para localização e identificação de danos em estágios iniciais em estruturas de aeronaves.

De Medeiros *et al.* (2018), desenvolve uma nova metodologia baseada em diferentes técnicas a serem aplicadas em sistema de monitoramento de integridade estrutural para estruturas impactadas de aeronáuticas. A pesquisa considera três métodos: método baseado em vibração, sherografia speckle e flexão após impacto.

3. MATERIAIS E METODOLOGIA

Neste capítulo é desenvolvida a metodologia e materiais utilizados no trabalho, que abrange desde o processo de produção de amostras, seguido do ensaio de tração com filmagem para Correlação Digital de Imagens, tratamento dos dados (ensaio de tração e imagens obtidas no DIC), validação e aplicação dos dados nos algoritmos SVM (ensaio de tração) e Yolov3 (imagens aplicadas no DIC) para se obter a classificação de dano em materiais compósitos.

Figura 23 - Fluxograma do experimento



Fonte: Elaborada pelo autor, 2020

3.1. DETECÇÃO DE DANOS EM AMOSTRAS DE FIBRA DE VIDRO – EPÓXI


Um grupo de amostras foi produzido para estudar a viabilidade e aplicação da metodologia proposta. O método consiste em utilizar técnicas de *machine learning* para a identificação de diferentes níveis de danos em materiais compósitos. O ensaio mecânico foi realizado com intuito de se obter o comportamento do material via ensaio de tração e por meio de imagens produzidas pela técnica de DIC. Em seguida foram usados os algoritmos SVM para classificação (“d0”, “d1” e “d2”) e Yolov3 para identificação da ocorrência de dano por vídeo (filmagem do ensaio de tração).

3.2. PROCESSOS DE FABRICAÇÃO DE AMOSTRAS

A resina epóxi (AR-260), da empresa Barracuda *Advanced Composites*, foi combinada com o catalisador também da mesma marca (AH-150) na proporção de 3 para 1 com um *pot life* de 50 minutos a 25°C.

A fibra de vidro utilizada foi do tipo unidirecional com densidade global de 412 g/m^2 . O layout do processo de fabricação é mostrado na Figura 24.

Figura 24 - Layout de produção de amostras



Fonte: Rosenstock (2019)

Para evitar absorção de água no processo, a resina foi mantida a 60°C antes do processo de fabricação. A resina epóxi foi adicionada diretamente no molde junto com o empilhamento da fibra de vidro. Foram usadas 8 camadas de fibras empilhadas em sequência $[0]_8$. O processo de fabricação pode ser descrito pelos seguintes passos:

- Aplicação da cera (Cera Tradicional Grand Prix) em uma fina camada no molde de vidro para impedir o colamento do material compósito durante a cura e facilitar o desmolde.
- Colocação de uma camada (anterior ao empilhamento de fibras) de tecido Peel PLY para ajudar o desmolde.
- Posicionamento da fibra de vidro.


As Figura 25 e Figura 27 demonstram como foram feitos os empilhamentos das fibras de vidro com seus respectivos danos.

Figura 25 - Sem dano – Com 08 camadas contínuas, com ângulo de 0°




Fonte: Elaborada pelo autor, 2020

Figura 26 - Dano 01 – Com 02 camadas centrais com cortes na seção horizontal



Fonte: Elaborada pelo autor, 2020

Figura 27 - Dano 02 – Com 04 camadas centrais com cortes na seção horizontal.



Fonte: Elaborada pelo autor, 2020


- Aplicação da mistura resina + catalisador sobre a fibra de vidro.
- Aplicação de mais uma camada de PLY (posterior ao empilhamento de fibras).
- Embalar o molde com plástico filme para produção de vácuo.
- Ligar a bomba de vácuo para produção de vácuo.
- Desligar a bomba de vácuo após 10 horas (depende do tempo de cura).
- Desmoldar a partir de 24 horas.
- Pintura de fundo branco com marcações em preto.

Figura 28 - Estrutura para colocação de fibras



Fonte: Rosenstock (2019)

Figura 29 – Estrutura de fabricação completa



Fonte: Rosenstock (2019).

Após desmoldado, os corpos de prova são cortados (Figura 30).

Figura 30 – Serra de corte usada para produção dos corpos de prova



Fonte: Rosenstock (2019)

Resultando em amostras com as dimensões apresentadas na Tabela 3.

Tabela 3 - Dimensões amostras

	D0		D1		D2	
	Largura	Espessura	Largura	Espessura	Largura	Espessura
1	27,58	2,93	27,29	3,4		
2	27,72	2,84	27,48	3,35	27,61	3,04
3	27,64	3	27,36	3,56	27,46	2,94
4	27,51	3	27,68	3,01	27,26	3,75
5	27,59	3,35	27,58	3,23	27,33	3,79
6	27,47	3,23	27,43	3,38	27,31	3,62
7	27,59	3,02	27,65	2,95	27,35	3,46
8	27,64	2,85	27,59	3,03	27,34	3,96
9	27,55	3,4	27,67	2,92	27,3	3,82
10	3,47	27,33	27,11	4,18	27,55	3,14
11	27,45	3,26	27,37	3,79	27,4	3,78
12	27,53	3,41	27,36	3,51	27,4	3,72
13	27,72	2,72	27,21	3,52	27,62	2,87
14	27,57	2,76	27,22	3,35	27,33	3,56
15	27,7	2,95	27,15	3,24	27,58	2,81
16	27,48	3,24	27,52	3,02	27,45	3,15
17	27,41	2,86	27,64	2,95	27,49	3,16
18	27,75	3,32	27,59	3,03	27,6	3,27

Fonte: Elaborada pelo autor, 2020

3.3. ENSAIO DE TRAÇÃO E FILMAGEM

O ensaio de tração foi realizado na máquina de tração EMIC DL 3000 (Figura 31), do tipo bifuso de bancada, com duas colunas guias cilíndricas paralelas na velocidade de 5mm/min. Foram realizados 18 ensaios de tração nos corpos de prova por tipo de dano (D0, D1, D2), totalizando 54 ensaios com uma taxa de aquisição de 2 pontos por segundo.

O ensaio foi realizado em duas etapas em paralelo, sendo a primeira etapa o ensaio de tração e a segunda etapa a filmagem do ensaio. Ambos os processos foram iniciados ao mesmo tempo. Os dados captados pelo ensaio de tração foram: tempo, força e deformação nas amostras. Na filmagem (Figura 32) foram captadas as matrizes de imagens dos frames. As aquisições de dados eram interrompidas com o

início da queda brusca de força nos corpos de provas, o que caracterizava o seu rompimento.

Figura 31 - Máquina de tração EMIC dl 3000



Fonte: Elaborada pelo autor, 2020

Figura 32 - Filmagem do ensaio de tração pelo equipamento DIC

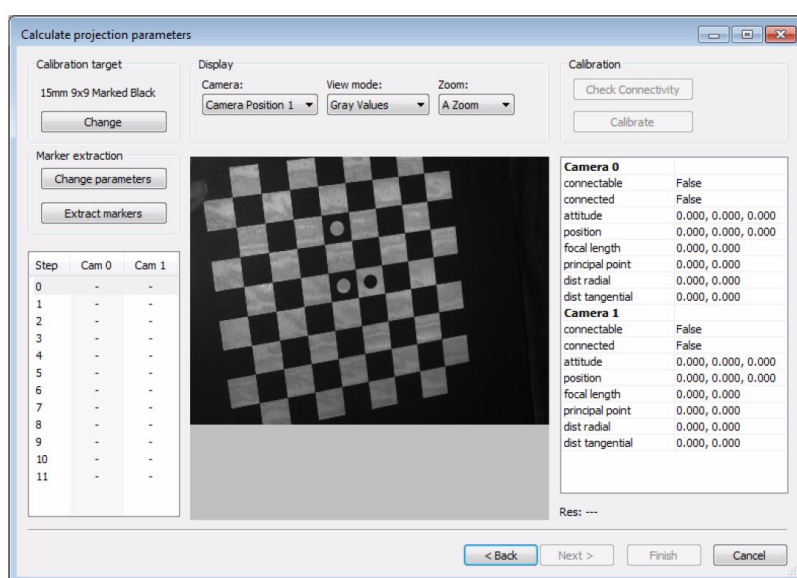


Fonte: Elaborada pelo autor, 2019

3.4. DIC

O programa utilizado de *Digital Image Correlation* foi o Q-400 Istra 4D. Primeiramente foi necessário ativar o repositório de dados. Em seguida foi necessário fazer a calibração das câmeras para calcular o parâmetro de projeção, no qual é uma função automática (Figura 33).

Figura 33 - Cálculo de parâmetros de projeção



Fonte: Q-400 Istra 4D Manual (2017).

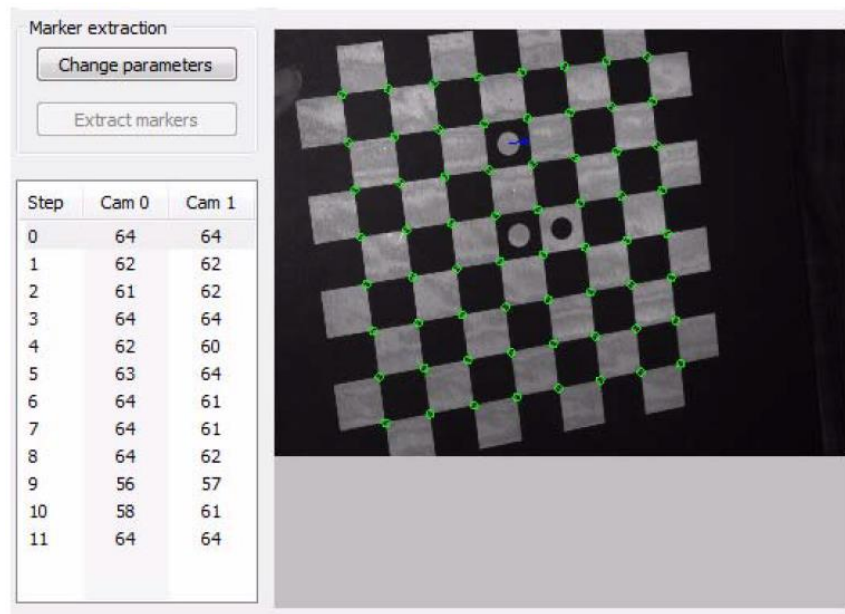
O software detectou o alvo de calibração e indicou os marcadores encontrados. Na seção opção de “Câmera”, foi selecionado mostrar a imagem para realizar a extração dos marcadores em “Marker Extration” (Figura 34). Nesta etapa foi feita a verificação da conectividade e cálculo dos parâmetros de projeção no qual era necessário a visibilidade dos marcadores.

Em seguida foi necessário ajustar os parâmetros de aquisição no qual foi selecionado o tipo de formato de imagem (AVI), definição de área de interesse e frequência de aquisição (5hz).

Após ajustar os parâmetros foi dado nome a série e, em seguida, iniciado o processo de filmagem em paralelo (mesmo tempo) do ensaio de tração. Na sequência foi feita a avaliação das imagens, selecionando quais foram usadas e usando a opção “High Accuracy”, no qual era otimizado a acurácia do que em relação a velocidade.

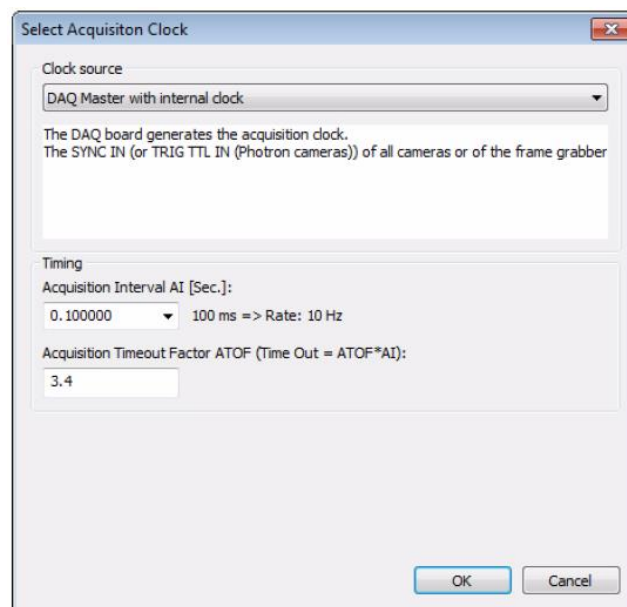
Foi selecionado a área de interesse (desenho de um quadrado), selecionando a área interna da figura, assim como a configuração de deslocamento no eixo “Y”. Também foi selecionando a transparência do objeto em “0” para que a imagem tenha somente os deslocamentos no eixo “Y” (Figura 36).

Figura 34 - Detecção dos marcadores




Fonte: Q-400 Istra 4D Manual (2017).

Figura 35 - Frequência de aquisição



Fonte: Q-400 Istra 4D Manual (2017).


Figura 36 - Exemplo de configuração



Fonte: Q-400 Istra 4D Manual (2017).

No final do processo os dados foram exportados no formato “Jpeg” finalizando o uso do equipamento, obtendo como resultado (Figura 37).

Figura 37 - Exemplo de Correlação de imagem digital (d1-cdp1)



Fonte: Elaborada pelo autor, 2020

3.5. TRATAMENTO DE DADOS

Os dados do ensaio de tração e sua filmagem aplicada no DIC sofreram tratamento para serem usados nos algoritmos SVM e Yolov3 respectivamente. Estes processos são descritos nos itens 3.5.1 e 3.5.2.

3.5.1. TRATAMENTO DOS DADOS DO ENSAIO DE TRAÇÃO

Com os dados de tração em mãos, a primeira etapa do processo de tratamento de dados foi construir os gráficos dos dados obtidos para selecionar somente pontos que estejam no regime elástico e que contenham o mesmo número de pontos (220 pontos – Figura 38 e 39).

Em seguida, os dados foram convertidos de ‘txt’ para ‘csv’ e transpostos. Com dados de força (N) e deslocamento (mm) foi possível montar a relação dessas variáveis com relação a todos os três tipos de dano.

$$\frac{força(N)}{deslocamento(mm)} = k \left(\frac{N}{mm} \right)$$


Na sequência foi armazenada a relação ‘ k ’, seguido do dicionário de seu dano em um vetor para cada uma das amostras.

$$CPD1_{d0} = (k_0, k_1, k_2, \dots, k_{219}, 0)$$

$$CPD1_{d1} = (k_0, k_1, k_2, \dots, k_{219}, 1)$$


$$CPD1_{d2} = (k_0, k_1, k_2, \dots, k_{219}, 2)$$

Figura 38 - Seleção de regime elástico



Fonte: Elaborada pelo autor, 2020

Figura 39 - D0-cdp1



*d0-cdp1.csv - Bloco de Notas

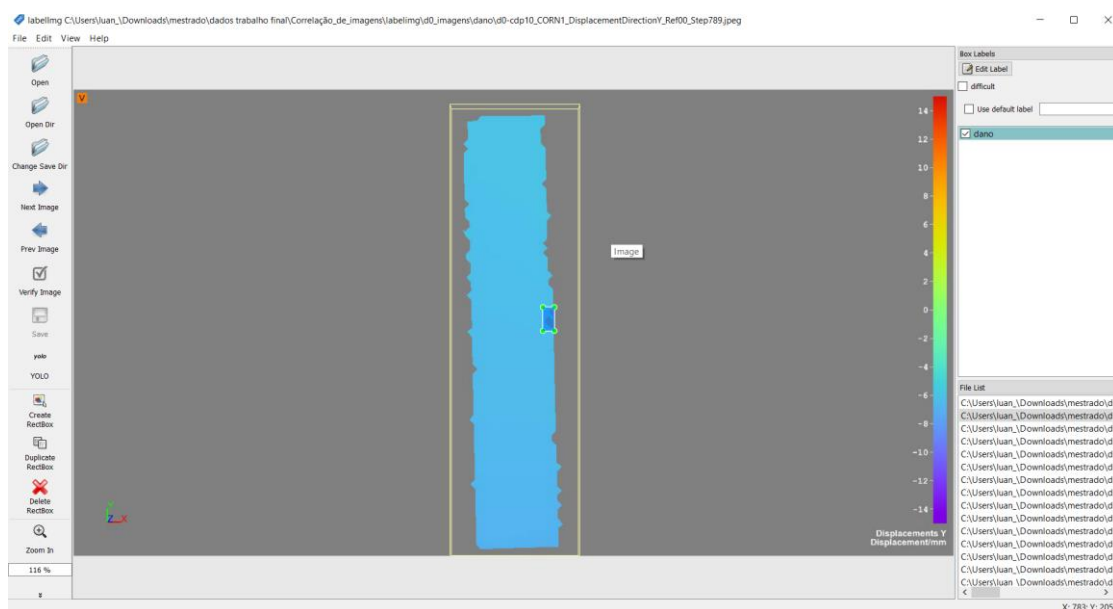
Arquivo	Editar	Formatar	Exibir	Ajuda
Tempo(s)	Deformação(mm)	Força(N)		
68.183	5.6734	2532.8		
68.683	5.7151	2573.0		
69.183	5.7568	2603.1		
69.583	5.7901	2643.3		
70.083	5.8317	2663.4		
70.417	5.8595	2703.6		
70.917	5.9012	2733.8		
71.367	5.9387	2774.0		
71.800	5.9748	2814.2		
72.300	6.0165	2844.3		
72.633	6.0442	2884.5		
73.133	6.0859	2914.7		
73.583	6.1234	2954.9		
74.083	6.1651	2985.0		
74.450	6.1956	3025.2		
74.950	6.2373	3055.4		
75.350	6.2706	3095.6		
75.850	6.3123	3125.8		

Fonte: Elaborada pelo autor, 2020

3.5.2. TRATAMENTO DOS DADOS DO DIC

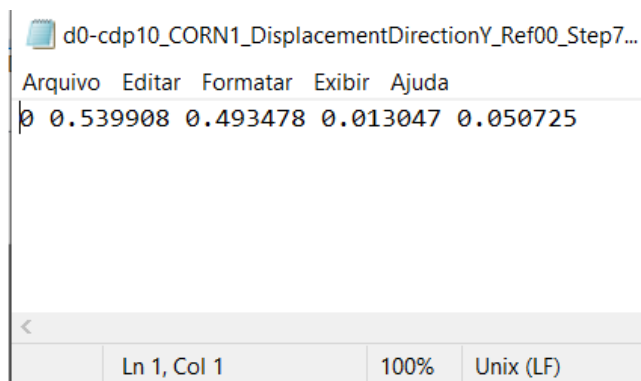
Com os dados de saída da filmagem do ensaio de tração pelo programa de DIC em formato “jpeg”, o primeiro passo foi selecionar as fotos que apresentavam dano; em seguida, selecionou-se as áreas identificadas para depois usá-las no treinamento de identificação de dano por imagem. Nesta etapa foi usado o programa “Labellmg”, que tem a função de produzir um arquivo “txt” com o dicionário da classe (dano), seguido de sua localização na imagem (Figura 40-41).

Figura 40 - Seleção de classe



Fonte: Elaborada pelo autor, 2020

Figura 41 - Dicionário e localização de classe



Fonte: Elaborada pelo autor, 2020

3.6. APLICAÇÃO DOS DADOS DE TRAÇÃO NO ALGORITMO SVM

Com os dados do ensaio de tração já tratados, eles são concatenados no eixo das abscissas; em seguida separados entre “x” e “y”, sendo:

$$x = \text{características}$$

$$y = \text{classe (tipo de dano)}$$

Utilizou-se o algoritmo da biblioteca “sklearn”, que precisa de alguns parâmetros para realizar a classificação:

Configuração do SVM com melhor performance (<https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html>)

- C=1.0
- kernel='rbf'
- degree=3
- gamma='scale'
- coef0=0.0
- shrinking=True
- probability=False
- tol=0.001
- cache_size=200
- class_weight=None
- verbose=False
- max_iter=1
- decision_function_shape='ovr'
- break_ties=False
- random_state=None

A relação de divisão dos dados foram:

- 30% de dados para teste.
- 70% dos dados para treino.

3.7. APLICAÇÃO DOS DADOS DE IMAGENS DO ENSAIO DE TRAÇÃO NO ALGORITMO YOLOV3

O algoritmo YOLOv3_train foi utilizado no Google Colab (<https://colab.research.google.com/>), que permite o uso de GPU (Tesla T4) em uma máquina virtual fornecida pela Google. Para o treinamento da rede foi necessário fornecer as imagens do ensaio de tração vindas da DIC, em conjunto com os arquivos (txt) com as posições dos danos ao longo do ensaio de tração (Figura 42).

Figura 42 - Google Colab GPU

```
# Check if NVIDIA GPU is enabled
!nvidia-smi
```

Thu Nov 26 19:42:18 2020

NVIDIA-SMI 455.38		Driver Version: 418.67		CUDA Version: 10.1	
GPU	Name	Persistence-M	Bus-Id	Disp.A	Volatile Uncorr. ECC
Fan	Temp	Perf	Pwr:Usage/Cap	Memory-Usage	GPU-Util Compute M. MIG M.
0	Tesla T4	Off	00000000:00:04.0	Off	0
N/A	55C	P8	12W / 70W	0MiB / 15079MiB	0% Default ERR!

Processes:						
GPU	GI	CI	PID	Type	Process name	GPU Memory Usage
	ID	ID				
No running processes found						

Fonte: Elaborada pelo autor, 2020

O armazenamento dos dados de treino (amostras 1 a 15 por tipo de dano) foi feito através do Google Drive, que foram acessados, via Google Colab, através da montagem do drive de acesso (Figura 43).

Em seguida, foi necessário montar a arquitetura do sistema Darknet (Redes Neurais Convolucionais de código aberto), que permite o uso de CPU (lento) e GPU (rápido), o qual possibilita o uso arquivos de configurações e pesos já pré-determinadas, assim como o uso da biblioteca “opencv” (Figura 44).

Figura 43 - Acesso ao Google drive via Colab

```
[ ] ## Montagem dos arquivos de classes com labeling
from google.colab import drive
drive.mount('/content/gdrive')
!ln -s /content/gdrive/My\ Drive/ /mydrive
!ls /mydrive
```

Fonte: Elaborada pelo autor, 2020

Figura 44 - Cópia dos arquivos darknet

```
!git clone https://github.com/AlexeyAB/darknet

Cloning into 'darknet'...
remote: Enumerating objects: 14479, done.
remote: Total 14479 (delta 0), reused 0 (delta 0), pack-reused 14479
Receiving objects: 100% (14479/14479), 13.15 MiB | 23.50 MiB/s, done.
Resolving deltas: 100% (9846/9846), done.
```

Fonte: Elaborada pelo autor, 2020

Foi fornecido também o nome (“Dano”) e número (“1”) de classes para serem treinados (Figura 45).

Figura 45 - Nome da classe selecionada nas imagens

```
!echo "Dano" > data/obj.names
!echo -e 'classes= 1\ntrain = data/train.txt\nvalid = data/test.txt\nnames = data/obj.names\nbackup = /mydrive/yolov3' > data/obj.data
!mkdir data/obj

mkdir: cannot create directory 'data/obj': File exists
```

Fonte: Elaborada pelo autor, 2020

Após a alteração do arquivo de configuração padrão da rede (yolov3_training.cfg) foi feita a alteração para identificação de apenas uma classe nos seguintes itens (<https://pjreddie.com/darknet/yolo/>) (Figura 46):

- “batch” para 64
- subdivisões 16
- número máximo de “batches” 4000
- números de classes para 1
- filtros para 18

Figura 46 - Alteração do arquivo de configuração para uma classe

```
[ ] !cp cfg/yolov3.cfg cfg/yolov3_training.cfg

!sed -i 's/batch=1/batch=64/' cfg/yolov3_training.cfg
!sed -i 's/subdivisions=1/subdivisions=16/' cfg/yolov3_training.cfg
!sed -i 's/max_batches = 500200/max_batches = 4000/' cfg/yolov3_training.cfg
!sed -i '610 s@classes=80@classes=1@' cfg/yolov3_training.cfg
!sed -i '696 s@classes=80@classes=1@' cfg/yolov3_training.cfg
!sed -i '783 s@classes=80@classes=1@' cfg/yolov3_training.cfg
!sed -i '603 s@filters=255@filters=18@' cfg/yolov3_training.cfg
!sed -i '689 s@filters=255@filters=18@' cfg/yolov3_training.cfg
!sed -i '776 s@filters=255@filters=18@' cfg/yolov3_training.cfg
```

Fonte: Elaborada pelo autor, 2020

O tempo de treinamento foi por volta de 6 horas (Figura 47).

Figura 47 - Treinamento da rede

```
# Start the training
!./darknet detector train data/obj.data cfg/yolov3_training.cfg darknet53.conv.74 -dont_show


v3 (mse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 94 Avg (IOU: 0.783486), count: 2, total_loss = 0.240804
v3 (mse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 106 Avg (IOU: 0.000000), count: 1, total_loss = 0.000002
total_bbox = 270281, rewritten_bbox = 0.002960 %
v3 (mse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 82 Avg (IOU: 0.000000), count: 1, total_loss = 0.000031
v3 (mse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 94 Avg (IOU: 0.868819), count: 6, total_loss = 0.780721
v3 (mse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 106 Avg (IOU: 0.000000), count: 1, total_loss = 0.000000
total_bbox = 270287, rewritten_bbox = 0.002960 %
```

Fonte: Elaborada pelo autor, 2020

Os resultados foram os “pesos” adequados para identificação de dano que foram aplicados a detecção nas imagens dos corpos de prova de teste, isto é, aqueles que não foram usados para o treinamento, amostras 16, 17 e 18, para cada tipo de dano.

A performance do “peso” do treinamento Yolov3 atingiu seu pico de mapeamento por volta das 4000 iterações (Figura 48). Recomendação de seus criadores de acordo com o número de classes (REDMON; FARHADI 2018). Utilizar “pesos” que possuem mais iterações pode causar *overfitting* fazendo com que a performance do algoritmo decaia.

Figura 48 - Performance Yolov3




Fonte: Elaborada pelo autor, 2020

3.8. DETECÇÃO POR VÍDEO


Para finalizar as detecções foram necessários apenas os caminhos dos vídeos de tração aplicados ao DIC (amostragem de teste), o peso resultado do treinamento (yolov3_training_4000.weights) e o arquivo de configuração de arquitetura (yolov3.cfg) para detecção. O resultado foram os vídeos com as detecções representados pelas imagens (Figura 49-Figura 57).

Figura 49 - d0-cdp16




Fonte: Elaborada pelo autor, 2020

Figura 50 - d0-cdp17




Fonte: Elaborada pelo autor, 2020

Figura 51 - d0-cdp18




Fonte: Elaborada pelo autor, 2020

Figura 52 - d1-cdp16




Fonte: Elaborada pelo autor, 2020

Figura 53 - d1-cdp17




Fonte: Elaborada pelo autor, 2020

Figura 54 - d1-cdp18




Fonte: Elaborada pelo autor, 2020

Figura 55 - d2-cdp16




Fonte: Elaborada pelo autor, 2020

Figura 56 - d2-cdp17



Fonte: Elaborada pelo autor, 2020

Figura 57 - d2-cdp18



Fonte: Elaborada pelo autor, 2020


4. RESULTADOS E DISCUSSÃO

Neste capítulo são reportados os principais resultados dos experimentos deste trabalho, que permitiu o estudo da classificação e da presença de dano em materiais compósitos utilizando de inteligência artificial (SVM e Yolov3).

4.1. COMPORTAMENTO DAS AMOSTRAS


A fabricação de todas as amostras foi realizada ao mesmo tempo para evitar variações no tempo de cura da resina, temperatura ambiente, umidade, vácuo da bomba na hora da produção, entre outros fatores. Entretanto, todos os procedimentos foram realizados de maneira manual, o que provocou grandes alterações dos comportamentos mecânicos dos corpos de prova durante os ensaios. Estas alterações podem ser confirmadas tanto pelos gráficos de tração das amostras 1, 2 e 5, dano d0 e 1,3 e 5, dano d1 (Figura 58 e Figura 59) e também pela variação das dimensões dos corpos de prova (Tabela 3 - Dimensões amostras) que teoricamente deveriam ser idênticos.

Figura 58 - Tração das amostras 1,2 e 5 dano d0, com diferentes limites de escoamento.



Fonte: Elaborada pelo autor, 2020

Figura 59 - Tração das amostras 1,3 e 5 dano d1, com diferentes limites de escoamento.



Fonte: Elaborada pelo autor, 2020

Esses comportamentos anômalos também podem ser evidenciados pela variação dos pontos de escoamento das amostras que participam do mesmo grupo de dano. Este comportamento é apresentado na Tabela 4.

Caso usássemos somente as variáveis do ponto de escoamento para fazer a identificação levando em conta o tipo de dano, teríamos grandes problemas entre as amostras d0 e d1, devido a média do escoamento de d0 ser menor do que d1 (as amostras com d0 teoricamente deveriam ter mais resistência a tração do que as amostras d1 devido a presença de dano).

Tabela 4 - Ponto de escoamento dos corpos de prova

Força no Ponto de Escoamento			
	d0	d1	d2
CDP 1	13267	14996	-
CDP 2	14674	13629	7236,5
CDP 3	14382	12553	7387,2
CDP 4	12704	11699	5487,7
CDP 5	12503	17086	5226,3
CDP 6	14714	12563	6362,1
CDP 7	12322	18553	5638,4
CDP 8	14081	14875	5628,4
CDP 9	14754	15920	4683,6
CDP 10	12272	11930	8321,9
CDP 11	13297	13478	8271,7
CDP 12	12714	12634	6934,9
CDP 13	13478	14282	7387,2
CDP 14	14423	13980	7246,5
CDP 15	12905	15950	7045,5
CDP 16	13820	10302	7648,5
CDP 17	12784	17890	7115,9
CDP 18	12292	12523	7477,7
Média	13410	14158	6741,5

Fonte: Elaborada pelo autor, 2020

4.1.1. EMPILHAMENTO E ORIENTAÇÃO DE FIBRAS

Dentro do processo de criação dos corpos de prova o fator que mais pode ter contribuído para diferença de comportamento de amostras de mesmo grupo de dano, podem ter sido o processo de empilhamento de fibras, que pode causar lacunas (vazios), má acomodação das camadas e diferentes orientações de fibra em sua confecção. Este problema pode ser ainda mais agravado para empilhamento das amostras com dano, pois o fato da fibra estar dividida em dois tornou o empilhamento manual nas camadas centrais ainda mais difícil.

4.2. RESULTADOS SVM

Após o tratamento de dados nas variáveis do ensaio de tração, elas foram inseridas no algoritmo SVM. O procedimento de treinamento e classificação foram repetidos dez vezes e seus resultados (matriz de confusão) armazenados. Estes dados foram usados para a montagem de performance dos resultados obtendo a

tabela de acurácia, precisão (das amostras d0, d1 e d2). Para cálculo do intervalo de confiança usou-se o valor de referência 95% ($\alpha = 0.05$) apresentando os resultados na Tabela 5.

Tabela 5 - Acurácia do modelo

	Acurácia
	0,813
	0,750
	0,750
	0,813
	0,625
	0,813
	0,938
	0,625
	0,688
	0,750
Média	0,756
Confiança 95%	0,056
Desvio padrão	0,090

Fonte: Elaborada pelo autor, 2020

De acordo com o resultado apresentado na Tabela 5, o modelo apresentou acurácia de 0.75 ± 0.05 , isto é, o modelo acerta a classificação dos corpos de prova em 75% das vezes. Isto demonstra que utilizar o algoritmo SVM como algoritmo para classificação de corpos de prova com presença de dano em um material que teve suas características mecânicas catalogada em três grupos (d0, d1 e d2), teve uma relevância estatística que fica ao seu favor no quesito continuidade de estudo. Entretanto, a não repetibilidade das amostras (comportamento mecânico variado dentro do grupo) dificultou na classificação de amostras do tipo d0 e d1. Estas amostras apresentaram comportamentos mecânicos muito parecidos, o que prejudicou a sua média de precisão (Tabela 6).

As amostras “d0” e “d1” obtiveram baixas precisões, $(69 \pm 11)\%$ e $(72 \pm 15)\%$ respectivamente, se comparadas às amostras d2, isto porque o comportamento mecânico das amostras d2 era muito diferente das outras, permitindo assim sua fácil classificação o que justifica sua alta precisão $(96\% \pm 0.05)$.

Tabela 6 - Precisão por amostra

	Precisão		
	d0	d1	d2
	0,710	0,800	1,000
	1,000	0,430	1,000
	0,780	0,500	0,800
	0,800	0,710	1,000
	0,500	0,750	1,000
	0,670	1,000	1,000
	0,860	1,000	1,000
	0,710	0,250	0,800
	0,430	0,750	1,000
	0,430	1,000	1,000
Média	0,689	0,719	0,960
Confiança 95%	0,110	0,151	0,050
Desvio padrão	0,178	0,244	0,080

Fonte: Elaborada pelo autor (2020).

4.3.RESULTADOS YOLOV3

Os dados usados para teste no YOLOv3 foram os corpos de prova 16, 17 e 18 dos grupos, sem dano (“d0”), dano tipo 1 (“d1”) e dano tipo 2 (“d2”), no qual o algoritmo fez somente inferência nas imagens que apresentavam de dano. A saída do algoritmo foi reunida em vídeo no formato AVI.

O resultado da identificação de danos por vídeos nas amostras 16, 17 e 18 dos grupos “d0”, “d1” e “d2”, podem ser identificados nos tempos da Tabela 7 em “Ocorrência de dano” no qual é localizado o tempo (segundos) para identificação do dano em vídeo. A verificação do período da presença de dano no ensaio de tração pode ser vista em “Ensaio de tração” nas colunas “Antes do dano” e “Depois do dano”. Os tempos de inicialização dos processos de captura dos dados do DIC e do ensaio de tração não são exatamente iguais apesar do pressionar o botão de inicialização da filmagem e do ensaio de tração serem simultâneos. Este fato acontece devido ao tempo de inicialização dos processos serem diferentes (*delay* de inicialização), entretanto foi considerado uma tolerância de até 1 segundo.

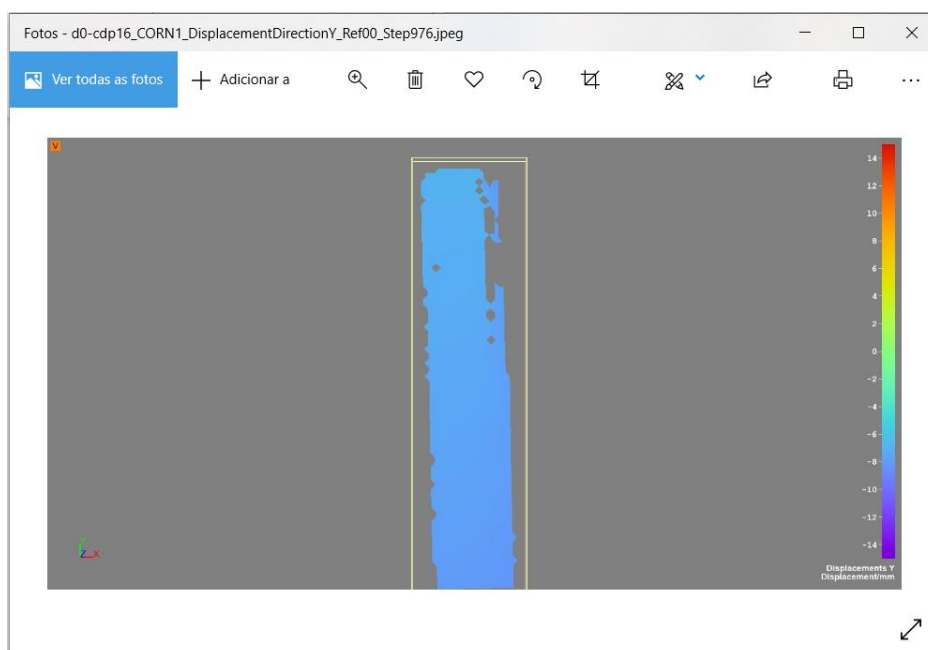
Tabela 7 - Comparação do tempo da presença de dano por imagens e ensaio de tração.

CDP	Ocorrência do dano		Ensaio de tração			
	imagem		Antes do dano		Depois do dano	
	Foto	tempo	força	tempo	força	tempo
d0-CDP16	976	195,2	13820	194,52	13066	195,02
d0-CDP17	864	172,8	13106	172,22	12995	172,45
d0-CDP18	870	174	13679	174,63	13779	175,03
d1-CDP16	727	145,4	10010	146,1	10000	146,6
d1-CDP17	877	175,4	17890	174,83	17870	174,87
d1-CDP18	800	160	15327	158,78	15327	159,28
d2-CDP16	669	133,8	7648,5	133,48	7507,8	133,98
d2-CDP17	616	123,2	6643,5	123,12	6583,2	123,37
d2-CDP18	686	137,2	7477,7	139,37	7216,4	139,55

Fonte: Elaborada pelo autor, 2020


Para exemplificar, é apresentado os dados que foram usados para montar a Tabela 7 utilizando-se das amostras “16”, dos grupos “d0”, “d1” e “d2”. Este exemplo foi construído através dos resultados (vídeo) do algoritmo de inferência, no qual é identificado o tempo de ocorrência de dano. Em seguida é comparado com o tempo de dano do ensaio de tração. Caso a variação do tempo fosse pequena (± 1 segundo) a detecção seria positiva.

Figura 60 - D0-CDP16 Ocorrência do dano foto (976)



Fonte: Elaborada pelo autor, 2020

Figura 61 - D0-CDP16 Ocorrência do dano detectada pelo Yolov3




Fonte: Elaborada pelo autor, 2020

Tabela 8 - Ensaio de tração, identificação dano d0-cdp16

Tempo(s)	Deformação (mm)	Força (N)
194.02	16,1600	13779
194.52	16,2010	13820
195.02	16,2430	13066
195.03	16,2440	12252

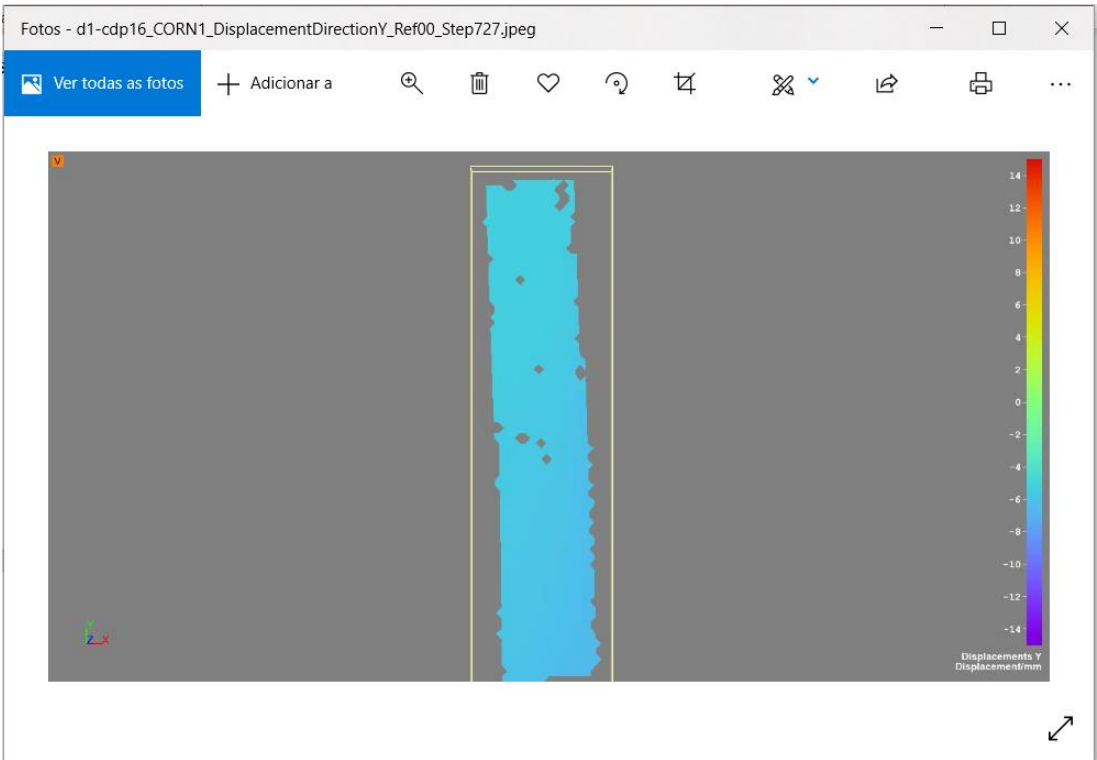
Fonte: Elaborada pelo autor, 2020

Figura 62 - Gráfico ensaio de tração d0-cdp16




Fonte: Elaborada pelo autor, 2020

Figura 63 – D1-CDP16 Ocorrência do dano foto (727)



Fonte: Elaborada pelo autor, 2020

Figura 64 - D1-CDP16 Ocorrência do dano detectada pelo Yolov3




Fonte: Próprio autor

Tabela 9 - Ensaio de tração, identificação dano d1-cdp16

Tempo(s)	Deformação (mm)	Força (N)
145,33	12,1030	9889,8
145,67	12,1310	9950,1
146,1	12,1670	10010
146,6	12,2080	10000

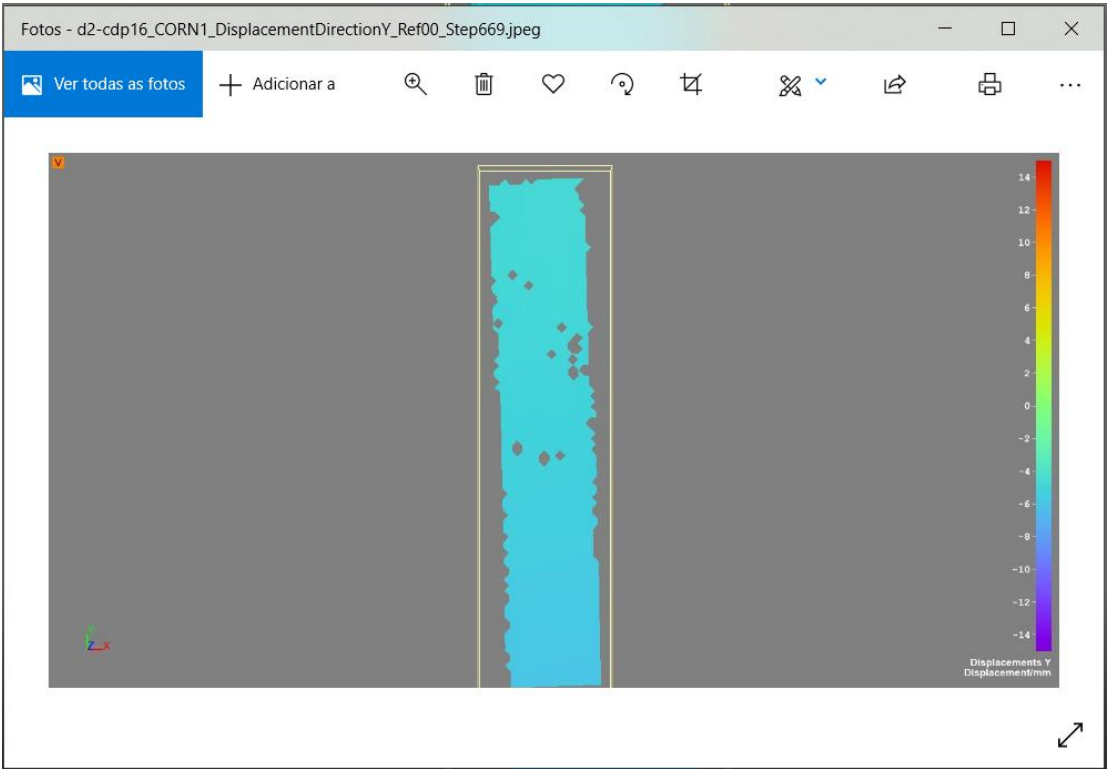
Fonte: Elaborada pelo autor, 2020

Figura 65- Gráfico ensaio de tração d1-cdp16




Fonte: Elaborada pelo autor, 2020

Figura 66 – D2-CDP16 Ocorrência do dano foto (669)



Fonte: Elaborada pelo autor, 2020

Figura 67 - D1-CDP16 Ocorrência do dano detectada pelo Yolov3




Fonte: Elaborada pelo autor, 2020

Tabela 10 - Ensaio de tração, identificação dano d2-cdp16

Tempo(s)	Deformação (mm)	Força (N)
132,78	11,0560	7568,1
133,12	11,0840	7608,3
133,48	11,1140	7648,5
133,98	11,1560	7507,8

Fonte: Elaborada pelo autor, 2020

Figura 68 - Gráfico ensaio de tração d2-cdp16



Fonte: Elaborada pelo autor, 2020

As amostras D0-CDP18 e D2-CDP18 tiveram uma variação do tempo de reconhecimento de dano de 1,03 e 2,35, segundos respectivamente, o que pode demonstrar a dificuldade do sistema em identificar danos significativos, isto é, como a filmagem capta somente o movimento da superfície, pode apresentar apenas danos superficiais que pouco alteram as propriedades mecânicas do CDP. Também deve ser levantada a hipótese em que a superfície possa se deslocar pouco podendo criar

a situação de falso positivo, em que o CDP tenha dano, mas sua superfície não tenha características suficientes para detectar dano.

Tomando a métrica de que as variações dos tempos de identificação de dano por vídeo para os dados do ensaio de tração sejam menores do que um segundo, algoritmo Yolov3 acertou sete das nove amostras. Apresentando precisão de 77,78%.

5. CONCLUSÃO

Os principais objetivos deste trabalho consistem em fazer um sistema de SHM utilizando-se da tecnologia de Inteligência artificial para classificação de amostras no quesito dano, assim como fazer a identificação da presença de dano por imagens processadas pelo DIC. Para realizar inspeções de maneira autônoma, promovendo, redução do erro humano, reduzindo os riscos de funcionamento, redução dos custos de inspeções e por fim conquistando o monitoramento contínuo de estruturas. Como consequências desse estudo foi possível obter:

- Entendimento do comportamento do material compósito (fibra de vidro) devido a fabricação manual, que promoveu o comportamento anômalo dos CDPs. O entendimento da variação do comportamento deixa ainda mais evidente que o processo de confecção das amostras deve ser revisado para melhorar a qualidade do processo como um todo.
- Compreensão que pelo motivo das amostras terem um comportamento variado, este fato pressionou a robustez dos algoritmos (teste dos limites de detecção) evidenciando suas funcionalidades no quesito inferência.
- Compreender o funcionamento do equipamento de DIC no quesito detecção dos deslocamentos, pois o material apresentou comportamento frágil fazendo com que os pontos de detecção deixassem de ser computados, permitindo assim a fácil detecção de dano através de imagens.
- Obter dimensionamento do custo computacional de identificação por imagens. Ter a disposição uma GPU de alto poder computacional mesmo que por 12 horas (tempo limite oferecido pelo Google Colab), permitiu usar um “dataset” de tamanho ideal para dimensão das detecções. Entretanto, caso fossem oferecidas mais características para o “dataset”, seria necessário pausar o treinamento a cada 12 horas e utilizar a transferência de aprendizado para continuar o treinamento. Já a classificação dos dados de tração utilizando-se SVM teve um custo computacional muito baixo devido à baixa dimensão dos dados.

Considerando o exposto, a aplicação de Inteligência Artificial para métodos de SHM apresentam boas perspectivas futuras, devido à redução de falhas humanas, redução de custo operacional, monitoramento contínuo, para detecção de dano em materiais de maneira não destrutível tornam-se vitais. Com o desenvolvimento de tecnologias que promovam reduções dos custos computacionais, tornam o uso de *Big Datas* mais acessível, assim como suas análises. Assim, as evoluções de técnicas baseadas em Inteligência Artificial têm a crescer, fazendo com que mais sistemas autônomos de monitoramentos de integridade estruturais sejam criados.

5.1. TRABALHOS FUTUROS

Para potencializar e aprimorar os resultados do presente trabalho, sugere-se:

- Aprimorar o método empilhamento de camadas de fibras de vidro para reduzir as lacunas (vazios) e deixar mais uniforme a orientação das fibras.
- Realizar ajustes para no processo de manufatura para uniformizar as espessuras dos corpos de prova, assim como a quantidade resina nas camadas.
- Realizar o treinamento completo da rede CNN (sem transferência de aprendizado) para detecção de dano utilizando DIC (Otimização da rede).
- Normalizar o espectro de cores para o limite de deslocamento, isto é, utilizar todas as cores para o deslocamento máximo dos pontos do corpo de prova.
- Testar o método em outros materiais de comportamento mecânico esperados.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABELLAN-NEBOT, Jose Vicente; SUBIRÓN, Fernando Romero. A review of machining monitoring systems based on artificial intelligence process models. *The International Journal of Advanced Manufacturing Technology*, v. 47, n. 1-4, p. 237-257, 2010.
- BABA, A., PASHA, M. G., AHAMMED, S. A., and TABASSUM, S. N. (2013). Introduction to Neural Networks Design Architecture. *International Journal of Scientific & Engineering Research*, 4(2):1–8.
- BATAXI, Chen X. *et al.* Strain monitoring on damaged composite laminates using digital image correlation. *Procedia Engineering*, v. 99, p. 353-360, 2015.
- BISHOP, Christopher M. *Pattern recognition and machine learning*. springer, 2006.
- BOSER, Bernhard E.; GUYON, Isabelle M.; VAPNIK, Vladimir N. A training algorithm for optimal margin classifiers. In: *Proceedings of the fifth annual workshop on Computational learning theory*. 1992. p. 144-152.
- BOTELHO EC, Rezende MC. O uso de Compósitos Estruturais na Indústria Aeroespacial. *Polímeros: Ciência e Tecnologia*. 2000; 10(2):E4-E10.
- BROWNJOHN, James MW. Structural health monitoring of civil infrastructure. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, v. 365, n. 1851, p. 589-622, 2007.
- CAMINERO, M. A. *et al.* Damage monitoring and analysis of composite laminates with an open hole and adhesively bonded repairs using digital image correlation. *Composites Part B: Engineering*, v. 53, p. 76-91, 2013.
- CARDER D.S. 1937, Observed vibrations of bridges. *Bull. Seismol. Soc. Am.* 27, 267–303. Smith L.M. 1996 In-service monitoring of nuclear-safety-related structures. *Struct. Eng.* 74, 210–211.
- CHEN, Z., CUDNEY, H., GIURGIUTIU, V., ROGERS, C., QUATTRONE, R., and BERMAN, J. (1997) “Full-Scale Ferromagnetic Active Tagging Testing of C-Channel Composite Elements,” *Smart Systems for Bridges, Structures, and Highways*, *Proceedings of SPIE*, Vol. 3,043, pp. 169–180.

- CHEVTCHENKO, Sérgio F. *et al.* A convolutional neural network with feature fusion for real-time hand posture recognition. *Applied Soft Computing*, v. 73, p. 748-766, 2018.
- CHU, T. C.; RANSON, W. F.; SUTTON, Michael A. Applications of digital-image-correlation techniques to experimental mechanics. *Experimental mechanics*, v. 25, n. 3, p. 232-244, 1985.
- CLARK, Jack. Why 2015 was a breakthrough year in artificial intelligence. *Bloomberg Technology* [online journal], v. 18, n. 1, 2015.
- CREVIER, Daniel (1993), *AI: The Tumultuous Search for Artificial Intelligence*, New York, NY: BasicBooks, ISBN 0-465-02997-3.
- DAS, Monalisa; SAHU, Sasmita; PARHI, Dayal R. A Review of Application of Composite Materials for Aerospace Structures and its Damage Detection Using Artificial Intelligence Techniques. Available at SSRN 3714181, 2020.
- DE MEDEIROS, Ricardo; VANDEPITTE, Dirk; TITA, Volnei. Structural health monitoring for impact damaged composite: a new methodology based on a combination of techniques. *Structural Health Monitoring*, v. 17, n. 2, p. 185-200, 2018.
- DENG, Naiyang; TIAN, Yingjie; ZHANG, Chunhua. *Support vector machines: optimization based theory, algorithms, and extensions*. CRC press, 2012.
- DETR 2001 List of Panel Engineers: Reservoirs Act 1975. Department of the Environment, Transportation and the Regions.
- DIAMANTI, K.; SOUTIS, C. Structural health monitoring techniques for aircraft composite structures. *Progress in Aerospace Sciences*, v. 46, n. 8, p. 342-352, 2010.
- ELVIN, N., and LEUNG, C. (1997) "Feasibility of Delamination Detection with Embedded Optical Fibers" *Smart Structures and Integrated Systems*, *Proceedings of SPIE*, Vol. 3,041, pp. 627–634.
- FARRAR, Charles R.; DOEBLING, Scott W.; NIX, David A. Vibration-based structural damage identification. *Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, v. 359, n. 1778, p. 131-149, 2001.

- FARRAR, C. R., & WORDEN, K. (2006). An introduction to structural health monitoring. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 365(1851), 303-315.
- GARCEZ, E. O. Análise Teórico-Experimental do Comportamento de Concretos Reforçados com Fibras de Aço Submetidos a Cargas de Impacto. 2005. 141 p. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.
- GASPARIN, Alexandre Luís. Adesão metal-polímero: dispositivos de medição e correlações físico-químicas. 2011.
- GENESERETH, Michael R.; NILSSON, Nils J. Logical foundations of artificial intelligence. Morgan Kaufmann, 2012.
- GEORGE, Annie; VIDYAPEETHAM, A. V. Anomaly detection based on *machine learning*: dimensionality reduction using PCA and classification using SVM. *International Journal of Computer Applications*, v. 47, n. 21, p. 5-8, 2012.
- GÉRON, Aurélien. Hands-on *machine learning* with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. O'Reilly Media, 2019.
- GIANCANE, S. *et al.* Fatigue damage evolution of fiber reinforced composites with digital image correlation analysis. *Procedia Engineering*, v. 2, n. 1, p. 1307-1315, 2010.
- GOIDESCU, Cristina *et al.* Damage investigation in CFRP composites using full-field measurement techniques: combination of digital image stereo-correlation, infrared thermography and X-ray tomography. *Composites Part B: Engineering*, v. 48, p. 95-105, 2013.
- GOODFELLOW, I., BENGIO, Y., and COURVILLE, A. (2016). Deep Learning. MIT Press. <http://www.deeplearningbook.org>.
- GORUNESCU, Florin. Data Mining: Concepts, models and techniques. Springer Science & Business Media, 2011.
- GOTTENBERG, William G. Some applications of holographic interferometry. *Experimental Mechanics*, v. 8, n. 9, p. 405-410, 1968.

- GUYON, Isabelle *et al.* A time delay neural network character recognizer for a touch terminal. In: Proceedings of the International Neural Network Conference, Paris, June 1990. 1990.
- HAGAN, M. T., DEMUTH, H. B., BEALE, M. H., and De JESÚS, O. (1996). Neural network design, volume 20. Pws Pub. Boston, 2 edition.
- HILD, François; ROUX, Stéphane. Digital image correlation: from displacement measurement to identification of elastic properties—a review. *Strain*, v. 42, n. 2, p. 69-80, 2006.
- HILD, F.; ROUX, S. Correli Q4: A software for-finite-elementdisplacement field measurements by digital image correlation. *Rapport interne LMT Cachan*, v. 269, 2008.
- HUANG, S. and RAMANAN, D. (2017). Expecting the Unexpected: Training Detectors for Unusual Pedestrians with Adversarial Imposters. In *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, volume 1.
- HUNG, Po-Chih; VOLOSHIN, A. S. In-plane strain measurement by digital image correlation. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, v. 25, n. 3, p. 215-221, 2003.
- JUNLIN, H., JIWEN, L., Yap-PENG, T., and JIE, Z. (2016). Deep Transfer Metric Learning. *IEEE transactions on image processing: a publication of the IEEE Signal Processing Society*, 25(12):5576–5588.
- KESSLER, Seth S. *et al.* Damage detection in composite materials using frequency response methods. *Composites Part B: Engineering*, v. 33, n. 1, p. 87-95, 2002.
- KOZA, John R. *et al.* Automated design of both the topology and sizing of analog electrical circuits using genetic programming. In: *Artificial Intelligence in Design'96*. Springer, Dordrecht, 1996. p. 151-170.
- KRIZHEVSKY, A., SUTSKEVER, I., and HINTON, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q., editors, *Advances in Neural Information Processing Systems 25*, pages 1097–1105. Curran Associates, Inc.
- KURIAN, Bibin; LIYANAPATHIRANA, Ranjith. Machine Learning Techniques for Structural Health Monitoring. In: *Proceedings of the 13th International*

- Conference on Damage Assessment of Structures. Springer, Singapore, 2020. p. 3-24.
- LECUN, Y., BENGIO, Y., and HINTON, G. (2015). Deep learning. *nature*, 521(7553):436.
- LIU, L., Ouyang, W., WANG, X., FIEGUTH, P., CHEN, J., LIU, X., and PIETIKÄINEN, M. (2018). Deep Learning for Generic Object Detection: A Survey. *arXiv preprint arXiv:1809.02165*.
- LORENA, Ana Carolina; DE CARVALHO, André CPLF. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43-67, 2007.
- MALESA, M. *et al.* Monitoring of civil engineering structures using Digital Image Correlation technique. In: *EPJ Web of Conferences*. EDP Sciences, p. 31014, 2010.
- MARINUCCI, Gerson. *Materiais compósitos poliméricos: Fundamentos e tecnologia*. São Paulo: Artliber Editora, 2011.
- MASERAS-GUTIERREZ, M., STASZEWSKI, W., Found, M., and WORDEN, K. (1998) "Detection of Impacts in Composite Materials Using Piezoceramic Sensors and Neural Networks" *Smart Structures and Materials 1999: Smart Structures and Integrated Systems*, Proceedings of SPIE, Vol. 3,329, pp. 491–497.
- MCCORDUCK, Pamela; CFE, Cli. *Machines who think: A personal inquiry into the history and prospects of artificial intelligence*. CRC Press, 2004.
- MITCHELL, Tom. Introduction to machine learning. *Machine Learning*, v. 7, p. 2-5, 1997.
- MOHRI, Mehryar; ROSTAMIZADEH, Afshin; TALWALKAR, Ameet. *Foundations of machine learning*. MIT press, 2018.
- MOUNTRAKIS, Giorgos; IM, Jungho; OGOLE, Caesar. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 66, n. 3, p. 247-259, 2011.
- MOURA, Marcelo Francisco de SF; DE MORAIS, Alfredo Manuel Balacó; DE MAGALHÃES, António Gonçalves. *Materiais compósitos: materiais, fabrico e comportamento mecânico*. 2005.

- NIELSON, M. A. (2015). Neural Networks and Deep Learning, volume 25. Determination press USA.
- OSUNA, Edgar; FREUND, Robert; GIROSIT, Federico. Training support vector machines: an application to face detection. In: Proceedings of IEEE computer society conference on computer vision and pattern recognition. IEEE, 1997. p. 130-136.
- PAN, S. J. and YANG, Q. (2010). A survey on transfer learning. IEEE Transactions on knowledge and data engineering, 22(10):1345–1359.
- PARDINI, Luiz C.; LEVY NETO, Flaminio. Compósitos estruturais: ciência e tecnologia. Edição. Ed. Edgard Blucher. São Paulo, 2006.
- PEREIRA, Luís Moniz. Inteligência Artificial: mito e ciência. Revista Colóquio-Ciências, v. 3, p. 1-13, 1988.
- PESCO, Dirce Uesu; BORTOLOSSI, Humberto José. Imagens digitais e matrizes. Revista Gazeta Matemática, n. 169, p. 44-48, 2013.
- PFEIFER, Niki; KLEITER, Gernot D. Uncertain deductive reasoning. In: The science of reason. Psychology Press, 2010. p. 161-182.
- PITTS, W. and MCCULLOCH, W. S. (1947). How we know universals the perception of auditory and visual forms. The Bulletin of mathematical biophysics, 9(3):127–147.
- POST, Daniel. Moiré interferometry at VPI & SU. Experimental Mechanics, v. 23, n. 2, p. 203-210, 1983.
- REDMON, J., DIVVALA, S., GIRSHICK, R., and FARHADI, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 779–788.
- REN, S., He, K., GIRSHICK, R., and SUN, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. In Advances in neural information processing systems, pages 91–99.
- REZENDE, Mirabel C.; BOTELHO, Edson C. O uso de compósitos estruturais na indústria aeroespacial. Polímeros, v. 10, n. 2, p. e4-e10, 2000.
- RISBET, Marion *et al.* Digital image correlation technique: application to early fatigue damage detection in stainless steel. Procedia engineering, v. 2, n. 1, p. 2219-2227, 2010.

- ROSENBLATT, Frank. Perceptron simulation experiments. *Proceedings of the IRE*, v. 48, n. 3, p. 301-309, 1960.
- ROSENSTOCK, Luísa V. - Fault Diagnosis in Composite Structures Using Artificial Neural Network and Principal Component Analysis, Universidade do Estado de Santa Catarina ,2019.
- RUSSELL, Stuart; NORVIG, Peter. *Artificial intelligence: a modern approach*. 2002.
- SAID, W.M., and STASZEWSKI, W.J. (2000) "Optimal Sensor Location for Damage Detection Using Mutual Information" 11th International Conference on Adaptive Structures and Technologies, Nagoya, Japan, October 23–26, pp. 428–435.
- SCHMIDHUBER, Jürgen. Deep learning in neural networks: An overview. *Neural networks*, v. 61, p. 85-117, 2015.
- SCURI, Antonio Escaño. *Fundamentos da Imagem Digital*. 2002. Rio de Janeiro, 2015.
- SHARMA, V., RAI, S., and DEV, A. (2012). *A Comprehensive Study of Artificial Neural Networks*. Internatio
- SIMON, Herbert Alexander. *The shape of automation for men and management*. New York: Harper & Row, 1965.
- SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- SMARSLY, Kay; DRAGOS, Kosmas; WIGGENBROCK, Jens. Machine learning techniques for structural health monitoring. In: *Proceedings of the 8th European Workshop on Structural Health Monitoring (EWSHM 2016)*, Bilbao, Spain. 2016. p. 5-8.
- SOHN, H., FARRAR, C. R., HUNTER, H. F., and WORDEN, K., 2001c, "Applying the LANL Statistical Pattern Recognition Paradigm for Structural Health Monitoring to Data From a Surface-Effect Fast Patrol Boat," Los Alamos National Laboratory Report, LA-13761-MS.
- SUN, Limin *et al.* Review of Bridge Structural Health Monitoring Aided by Big Data and Artificial Intelligence: From Condition Assessment to Damage Detection. *Journal of Structural Engineering*, v. 146, n. 5, p. 04020073, 2020.

- SUTTON, M.A., WOLTERS, W.J., PETERS, W.H., RANSON, W.F., MCNEILL, S.R., 1983. Determination of displacements using an improved digital correlation method. *Image and Vision Computing* 1 (3), 133–139
- SZEGEDY, C., VANHOUCKE, V., IOFFE, S., SHLENS, J., and WOJNA, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 2818–2826.
- VALIATI, Gustavo R.; MENOTTI, David. Detecting Pedestrians with YOLOv3 and Semantic Segmentation Infusion. In: *2019 International Conference on Systems, Signals and Image Processing (IWSSIP)*. IEEE, 2019. p. 95-100.
- WANG, Lei; YUAN, F. G. Group velocity and characteristic wave curves of Lamb waves in composites: Modeling and experiments. *Composites science and technology*, v. 67, n. 7-8, p. 1370-1384, 2007.
- WORDEN, Keith; LANE, A. J. Damage identification using support vector machines. *Smart materials and structures*, v. 10, n. 3, p. 540, 2001.
- ZHAO, Z.-Q., ZHENG, P., Tao XU, S., and WU, X. (2018). Object Detection with Deep Learning: A Review. *IEEE transactions on neural networks and learning systems*.
- Zhu, Man, *et al.* "Digital image correlation assisted characterization of Mode I fatigue delamination in composites." *Composite Structures* 253 (2020): 112746.