



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA NAVAL

**REDE NEURAL CONVOLUCIONAL (CNN)
APLICADA NA ANÁLISE DE RISCO DE
ACIDENTES DAS EMBARCAÇÕES QUE
NAVEGAM NOS RIOS DA AMAZÔNIA**

ARIEL VICTOR DO NASCIMENTO

Orientação: Prof. Dr. Marcus Pinto da Costa da Rocha

Coorientação: Prof. Dr. Valcir João Farias da Cunha

Belém

2022

ARIEL VICTOR DO NASCIMENTO

**REDE NEURAL CONVOLUCIONAL (CNN)
APLICADA NA ANÁLISE DE RISCO DE
ACIDENTES DAS EMBARCAÇÕES QUE
NAVEGAM NOS RIOS DA AMAZÔNIA**

Dissertação de Mestrado Submetida
ao Corpo Docente do Programa de
Pós-Graduação em Engenharia Naval
da Universidade Federal do Pará
como requisito parcial para obtenção
do Título de Mestre em Engenharia
Naval da Universidade Federal do
Pará

Orientação: **Prof. Dr. Marcus Pinto da Costa da Rocha**

Coorientação: **Prof. Dr. Valcir João Farias da Cunha**

Belém

2022

Nascimento, Ariel Victor do.

Desenvolvimento de rede neural convolucional para análise do disco de plimsoll de uma embarcação com propósito de avaliar o risco de acidente / Ariel Victor do Nascimento

Dissertação de Mestrado - Universidade Federal do Pará, Belém, 2022.

Orientador - Marcus Pinto da Costa da Rocha.

1. Estabilidade. 2. Rede Neural Convolucional.
3. Segurança da Navegação, 4. Inteligência Artificial,
5. Aprendizado Profundo.

UFPA / BC

006.32 CDD(22.ed.) MEI2008-049

ARIEL VICTOR DO NASCIMENTO

**REDE NEURAL CONVOLUCIONAL (CNN) APLICADA NA ANÁLISE
DE RISCO DE ACIDENTES DAS EMBARCAÇÕES QUE NAVEGAM
NOS RIOS DA AMAZÔNIA**

Dissertação de Mestrado Submetida ao Corpo Docente do Programa de Pós-Graduação em Engenharia Naval da Universidade Federal do Pará como requisito parcial para obtenção do Título de Mestre em Engenharia Naval.

Conceito: _____

Belém, 30 de Outubro de 2022

Banca Examinadora

Prof. Dr. Marcus Pinto da Costa da Rocha
PPGENAV/UFPA
Orientador

Prof. Dr João Farias da Cunha (SUPLENTE)
PPGENAV/UFPA
Coorientador

Prof. Dr. Miercio Neto
PPGME/UFPA
Examinador Interno

Profa. Dra. Lucelia Marques Lima da Rocha
SEDUC/PA
Examinador Externo

Em memória de José Alexandre Lopes Valente, pai, professor, homem íntegro, sábio e amigo, uma pessoa incrível e serva de Deus, que se manteve presente em todos os momentos e que sempre se alegrava pelas conquistas dos amigos. Grande parte das minhas conquistas foram graças a ele, inclusive o mestrado. Obrigado por todo incentivo que me deu, continuará sendo sempre meu pai do coração.

Lista de Tabelas

1	Arquitetura da Rede para classificação de embarcações	48
2	Arquitetura da Rede para classificação do Disco de Plimsoll	49

Lista de Figuras

1	Canoa	10
2	CAT BAM I da empresa Rodofluvial Banav	11
3	Ferry Boat	12
4	Iate	12
5	Navio de Guerra Solimões (V-24)	13
6	Veleiro “Cisne Branco”	14
7	Distribuição territorial dos Distritos Navais	15
8	VF/DES por DN	16
9	Vítimas Fatais (VF), Desaparecidos (DES) e Feridos (FE) por DN	16
10	Princípio de Arquimedes	18
11	Pontos de referência para Estabilidade Transversal	20
12	Localização do Centro de Carena em diferentes inclinações	21
13	Posição das referências em um navio inclinado	22
14	Seção Transversal do Navio	23
15	Reserva de Flutuabilidade	24
16	Gráfico das curvas de estabilidade	24
17	G na mesma posição que M	25
18	G acima de M	26
19	Disco de Plimsoll	27
20	Leve	28
21	Carregado	29
22	Sobrecarregado	29
23	Áreas de aplicação da Inteligência Artificial	30
24	Subgrupos da Inteligência Artificial	32
25	Neurônio Biológico Genérico	33
26	Neurônio Artificial	34
27	Rede Neural Artificial	35
28	Perceptron	36
29	Solução linearmente separável	37
30	Solução linearmente não-separável	37

31	Visão geral da arquitetura de uma Rede Neural Convolutacional	41
32	Mapa de característica de uma arquitetura convolutacional	41
33	Aplicação de max-pooling 2x2 em uma imagem 4x4	43
34	Rede neural totalmente conectada	44
35	Fluxograma 1 – Etapas do método aplicado a CNN	50
36	Exemplo de Imagens utilizadas das embarcações - Banco de dados	51
37	Exemplo de Imagens utilizadas das embarcações - Banco de dados	52
38	Exemplo de Imagens utilizadas dos disco de plimsoll - Banco de dados	52
39	Fluxograma 1 – Etapas do método aplicado a CNN	53
40	Valores de precisão (<i>accuracy</i>) e perda (<i>loss</i>)	55
41	a) Navio Militar, b) Canoa, c) Iate	56
42	a) Veleiro, b) Canoa, c) Catamarã	57
43	Resultado da previsão do resultado para treinamento de 30 épocas	58
44	Resultado da previsão do resultado para treinamento de 50 épocas	59
45	Resultado da previsão do resultado para treinamento de 75 épocas	60
46	a) Leve; b) Leve; c) Leve	61
47	a) Leve; b) Sobrecarregada; c) Carregada	62
48	Resultado da previsão do resultado para treinamento de 20 épocas com 5 passos por época	63
49	a) Sobrecarregada; b) Leve	64
50	Simulação do disco de plimsoll de uma mesma embarcação	64
51	Acidentes por tipo de embarcação de 2020	73
52	acidentes por tipo de embarcação de 2021	74

LISTA DE ABREVIATURAS E SIGLAS

CNT – Confederação Nacional do Transporte

IAFN – Inquérito Administrativo sobre Acidentes e Fatos da Navegação

NORMAM – Normas de Autoridade Marítima

CNN – Convolutional Neural Network

IA – Inteligência Artificial

RN – Redes Neurais

CSN – Certificado de Segurança da Navegação

SC – Sociedades Classificadoras

LISTA DE SÍMBOLOS

CG – Centro de Gravidade (CG)

δ – Deslocamento (t)

ρ – Densidade do fluido (t/m³)

∇ – Volume deslocado (m³) **P** – peso (t)

M – Momento (N.m)

K – Quilha

B – Centro de Carena

G – Centro de Gravidade

M – Metacentro

KG – Altura do Centro de Gravidade em relação a Quilha

KB – Altura do Centro de Carena em relação a Quilha

KM – Braço Metacêntrico

BM – Raio Metacêntrico

GZ – Braço de Endireitamento

BL – Borda Livre

Sumário

1	INTRODUÇÃO	3
1.1	Justificativa	4
1.2	Hipótese	5
1.3	Objetivos	5
1.3.1	Objetivo geral	5
1.3.2	Objetivos específicos	5
1.4	Estrutura do Trabalho	5
2	REVISÃO BIBLIOGRÁFICA	7
3	FUNDAMENTAÇÃO TEÓRICA	10
3.1	Embarcação e seus tipos de acordo com a NORMAM	10
3.2	Segurança da Navegação	14
3.3	Estabilidade	17
3.3.1	Princípio de Arquimedes	17
3.3.2	Momento	19
3.3.3	Centro de Gravidade dos objetos	19
3.3.4	Estabilidade Transversal	20
3.3.5	Braço de Endireitamento	22
3.4	Disco de Plimsoll	26
3.5	Inteligência Artificial (IA)	30
3.6	Machine Learning (ML)	30
3.6.1	Deep Learning (DL)	31
3.6.2	Rede Neurais Artificiais (RNA)	32
3.6.3	Perceptron	36
3.6.4	Função Softmax	37
3.6.5	Entropia cruzada	38
3.6.6	Unidade Linear Retificada (ReLU)	39
3.6.7	Redes Neurais Convulocionais (CNN)	39
4	METODOLOGIA	46
4.1	Ferramentas	46

4.2	Arquitetura da Rede	47
4.3	Fluxo do processamento	49
5	ANÁLISES DOS RESULTADOS	55
6	CONCLUSÕES	65
	REFERÊNCIAS	65
	ANEXO	72

RESUMO

A segurança na navegação é um assunto importante para manter o bem estar e integridade dos passageiros e da carga. Existem muitas regras a serem seguidas para avaliar a segurança, os certificadores e classificadores são responsáveis por garantir o cumprimento de todas essas regras que asseguram a integridade das embarcações, no entanto, isso não é suficiente. O Inquérito Administrativo de Acidentes e Fatos Navais (IAFN), documento elaborado pela Marinha do Brasil, coleta informações e cria um banco de dados para mostrar quantos acidentes ocorrem no Brasil por região, as quais são definidas como Distritos Navais (DN). O 4º Distrito Naval, em que está inserido o estado do Pará, foi o primeiro em acidentes ocorridos no ano 2020 e o terceiro no ano 2021. Devido a essas ocorrências de acidentes foram utilizados conceitos de inteligência artificial, **machine learning and deep learning** aplicados nesta área. Com o objetivo de auxiliar neste processo, este trabalho propõe desenvolver uma aplicação utilizando Rede Neural Convolutiva (CNN) para reconhecimento de imagens (Embarcações e Disco de *plimsoll*). Neste sentido, utilizou-se uma técnica de aprendizado de Rede Neural Convolutiva (CNN) que permite identificar o tipo de embarcação através de um banco de imagens fornecidas, o mesmo método foi aplicado para identificar se há risco de acidente com a embarcação mediante análise de imagens do disco de *plimsoll*. Para a realização dos treinamentos das CNNs, foram avaliadas seis diferentes arquiteturas de rede com: alteração do número de filtros em cada camada convolutiva; variação da quantidade de camadas convolucionais e; utilização de transferência de aprendizado da rede VGG-16 com a técnica de ajuste fino. Os resultados alcançados neste trabalho são promissores e demonstram a viabilidade do emprego de Rede Neural Convolutiva como método para identificação das imagens das embarcações como do disco de *plimsoll*).

PALAVRAS-CHAVE: *Disco de Plimsoll; Rede Neural Convolutiva; Segurança da Navegação; Inteligência Artificial; Aprendizado Profundo.*

ABSTRACT

Navigation safety is an important issue to maintain the well-being and integrity of passengers and cargo. There are many rules to follow to assess safety, certifiers and classifiers are responsible for ensuring compliance with all these rules that ensure the integrity of vessels, however, this is not enough. The Administrative Inquiry of Naval Accidents and Facts (IAFN), a document prepared by the Brazilian Navy, collects information and creates a database to show how many accidents occur in Brazil by region, which are defined as Naval Districts (DN). The 4th Naval District, in which the state of Pará is located, was the first in accidents that occurred in 2020 and the third in 2021. Due to these accidents, concepts of artificial intelligence, machine learning and deep learning were used. applied in this area. In order to assist in this process, this work proposes to develop an application using Convolutional Neural Network (CNN) for image recognition (Vessels and Disc of *plimsoll*). In this sense, a Convolutional Neural Network (CNN) learning technique was used, which allows identifying the type of vessel through a bank of images provided, the same method was applied to identify if there is a risk of accident with the vessel through analysis of disk images of *plimsoll*. To carry out the training of the CNNs, six different network architectures were evaluated with: changing the number of filters in each convolutional layer; variation in the amount of convolutional layers and; use of transfer of learning from the VGG-16 network with the fine-tuning technique. The results achieved in this work are promising and demonstrate the feasibility of using the Convolutional Neural Network as a method for identifying the images of vessels as the disk of *plimsoll*).

KEYWORDS: *Plimsoll Disk; Convolutional Neural Network; Safety of Navigation; Artificial Intelligence; Deep Learning.*

1 INTRODUÇÃO

No Brasil existem muitas vias navegáveis, porém, de acordo com um estudo elaborado pelo Confederação Nacional do Transporte (CNT, 2019), apenas 30% das vias são utilizadas. Em questão numérica, dos 63 mil quilômetros de rios com potencial de navegação, apenas 19,5 mil quilômetros são de fato utilizados. A partir do estudo, também pode-se afirmar que na região Amazônica, cerca de 10 milhões de passageiros são transportados por ano e que nos últimos 8 anos, até o ano do referido estudo, houve um crescimento de 34,8% de transporte de cargas.

Contudo, com o acréscimo da demanda do transporte fluvial, conseqüentemente aumenta a probabilidade de acidentes. A marinha, por sua vez, elaborou um documento denominado de Inquérito Administrativo sobre Acidentes e Fatos da Navegação (IAFN), que coleta e organiza dados de acidentes da navegação conforme: a natureza, o tipo de embarcação, quantidade por ano, distrito naval.

Os Distritos Navais, segundo o decreto n° 2.153, possuem inúmeras atribuições, sendo uma delas a de acompanhar o tráfego marítimo. Para que pudesse cobrir todo o território brasileiro foram criados 9 distritos navais. O 4° Distrito Naval é responsável pelos estados do Amapá (AP), Maranhão (MA), Piauí (PI) e o Pará (PA), sendo este último a região do estudo.

Em 2020 cerca de 34% das ocorrências pertencem ao 4° distrito naval responsável por parte dos estados do norte, estando em 1° lugar dentre os distritos. Alguma das causas que levam aos acidentes nos rios se deve ao fato de que os barcos, este sendo o meio de transporte que teve mais ocorrências, devido ao excesso de peso ou posicionamento errado de cargas e passageiros.

O peso total e a posição dos pesos influenciam diretamente na estabilidade de uma embarcação e para poder ser avaliado, existem critérios de análise, para este caso, a Borda Livre, a qual é a distância da linha d'água para o convés principal e a inclinação transversal serão abordados. Sobre o posicionamento das cargas, não sendo feito de forma adequada pode acarretar em uma inclinação para um dos bordos, que são as laterais da embarcação, chamado de adernamento.

Quando uma embarcação aderna é possível observar que um dos bordos acaba ficando com uma altura baixa de Borda Livre, segundo exemplos de Dokkun (2013b),

e com isso acaba não passando nas exigências estabelecidas pelas Normas de Autoridade Marítima (NORMAM). No caso do excesso de passageiros, a borda livre dos bordos já diminui, porém se agrava mais ainda quando se posiciona as cargas e passageiros de forma errônea, o que é muito comum, isso eleva o risco da queda de pessoas no rio e até mesmo o naufrágio da embarcação. Por isso é muito importante manter um mínimo de altura para a Borda Livre, conforme previsto pela Norma de Autoridade Marítima para Navegação Interior – NORMAM 02 (MARINHA DO BRASIL, 2005).

Para avaliar os riscos de acidente de uma embarcação devido a borda livre, será utilizado uma das técnicas de Aprendizado Profundo (*Deep Learning*), que são as chamadas de Redes Neurais Convolucionais (*Convolutional Neural Network - CNN*). Essa técnica de programação está inserida dentro do ambiente de Inteligência Artificial (I.A.), ao qual tem demonstrado ser bastante eficaz para problemas com imagens, como: classificação, reconhecimento de padrões (RONNEBERGER et al., 2015), extração de caracteres (OCR's) (MICROSOFT, 2018) e detecção de objetos (GOOGLE, 2017), o reconhecimento de navio usando mapa auto-organizáveis distribuídos (LOBO, 2009).

Com base nos dados fornecidos pela marinha e o avanço das técnicas de *Deep Learning*, objetiva-se desenvolver um código de CNN capaz de classificar imagens de embarcações regionais, a partir de uma análise da borda livre e por fim determinando se a condição da embarcação apresenta risco de perda de estabilidade.

1.1 Justificativa

O meio de transporte fluvial possui grande intensidade de fluxo anual de passageiros (CNT 2019), é importante também avaliar os meios de segurança existentes, conforme a autora Lacerda (2015) afirma:

“É primordial uma análise holística dos meios de segurança disponíveis que garantam a integridade da carga transportada, da propriedade, do meio ambiente e principalmente dos tripulantes e passageiros.” (LACERDA, 2015, pág.26)

Porém muitos passageiros que embarcam não têm conhecimento sobre como funciona a estabilidade de uma embarcação, por isso muitas vezes lotam os barcos, algo que acontece com frequência na região.

Portanto, com o avanço da computação e técnicas de inteligências artificiais, como Redes Neurais, e com a análise no histórico de ocorrência de acidentes na navegação

obtidos pelos dados da IAFN, seria importante levantar o questionamento: É possível uma I.A. com tantas contribuições para a sociedade, colaborar com a redução de índices de acidentes fluviais alertando sobre o risco de acidente para os passageiros antes da navegação?

1.2 Hipótese

A programação com Redes Neurais Convolucionais (CNN) conseguirá avaliar uma embarcação através das bordas livres a partir de imagens e indicar se apresenta algum risco de perda de estabilidade seja por excesso de peso ou posicionamento errado de carga e passageiro.

1.3 Objetivos

1.3.1 Objetivo geral

Desenvolver uma Rede Neural Convolucional (CNN) para analisar o risco de acidente das embarcações através da identificação das imagens obtidas do barco (disco de *plimsoll*), garantindo maior segurança na navegação nos rios da Amazônia.

1.3.2 Objetivos específicos

1. Coletar dados das embarcações e do *disco de plimsoll*.
2. Criar um banco de dados
3. Elaborar um código de inteligência artificial usando a técnica de Redes Neurais Convolucionais
4. Analisar a estabilidade da embarcação através do disco de plimsoll.
5. Avaliar a taxa de *falso positivo* (FP).
6. Identificar se a embarcação apresenta risco de instabilidade.

1.4 Estrutura do Trabalho

A estrutura do trabalho é dividida por capítulos, no qual o capítulo 2, trata sobre referencial teórico, onde será abordado a segurança da navegação, tipos de embarcações,

estabilidade e conceitos importantes sobre a inteligência artificial, machine learning e deep learning, e Redes Neurais Convolucionais. No capítulo 3, aborda-se a metodologia, explicando o processo do desenvolvimento do código. No capítulo 4, menciona-se o atual estado da obra, enquanto no capítulo 5 os resultados esperados. No Capítulo 6 apresenta-se o cronograma de atividades a desenvolver. No capítulo 7 as referências e no capítulo 8 os anexos.

2 REVISÃO BIBLIOGRÁFICA

Reconhecimento de imagens tem sido amplamente utilizado em vários ramos de pesquisas, como na medicina, para diagnósticos de uma doença a partir de análise dos resultados de exames; na agricultura, aplicado na identificação de pragas nas plantações; nos carros autônomos, substituindo a visão humana para as tomadas de decisões; dentre outras aplicações (FERREIRA, 2017; PRETO, 2018; TRINDADE, 2018; VOGADO et al., 2019).

Um dos métodos que tem sido aplicado com êxito no processamento e análise de imagens digitais, com alta eficácia para solucionar problemas de reconhecimento de padrões e objetos em imagens, é a Rede Neural Convolutiva (CNN) (ALMEIDA, 2018).

Visando a identificação dos componentes de uma linha ferroviária, assim como a indicação de desintegração e lascas de seus dormentes, a partir de análise de imagens, Gilbert, Patel e Chellappa (2015) aplicaram Redes Neurais totalmente Convolutivas para classificação de 10 classes de materiais. Essa arquitetura foi proposta pelo desafio de extrair informações precisas de imagens geradas por câmeras instaladas em veículos em movimento, na qual apresentam fundos distorcidos no ambiente ferroviário. A abordagem deste trabalho resultou em uma acurácia de classificação de material de 93,35% e comprovou a alta capacidade das Redes Neurais Convolutivas em capturar padrões mais complexos, enquanto reutiliza padrões aprendidos com níveis crescentes de abstração que são compartilhados entre todas as classes.

Seguindo a mesma linha, Faghieh-Roohi et al. (2016) aplicaram uma solução de Rede Neural Convolutiva (CNN) para detecção automática de defeitos na superfície de trilhos. Neste trabalho, foram utilizadas imagens brutas como entrada para o modelo de classificação e aplicadas em três estruturas diferentes de CNNs (pequena, média e grande), em tamanho e números de parâmetros, na qual foram comparados quanto à acurácia da classificação e ao tempo de computação. A rede foi otimizada usando um método de descida de gradiente de minilotes. Neste artigo, foram relatados três tipos dos resultados experimentados, inicialmente com seis 16 classes de classificação (normal, solda, defeito leve, defeito médio, defeito grande e junta) em que foi constatada uma alta porcentagem de resultados falsos. A partir de então, foram integradas as classes normal e solda como Normal e todas as três classes de defeitos como uma única classe. Desta

forma, uma nova avaliação de desempenho dos modelos de CNNs foi apresentada com as três classes: Normal, Defeito e Junta. Também foi apresentado o desempenho dos três modelos da CNN (pequeno, médio e grande) para as classificações multi-classe (3 classes) e binária (normal e defeito) com base nas médias das métricas de desempenho calculadas e nos desvios padrões correspondentes. Como resultado, o desempenho da classificação de defeitos alcançou quase 92% de acurácia nas três estruturas de rede, sendo a grande a de maior valor e com maior tempo gasto para o treinamento. Foi constatado que o treinamento de duas classes apresentou uma diferença de aproximadamente 1% de acurácia superior em relação o de três classes, o que validou um bom desempenho no treinamento de multi-classes. (FAGHIH-ROOHI et al., 2016).

Com o mesmo objetivo de detectar superfícies defeituosas de trilhos, Shang et al. (2018) propuseram uma abordagem baseada na combinação de técnicas de processamento de imagens e Rede Neural Convolutacional. O método foi projetado para classificar os trilhos como defeituosos ou intactos. Para a localização dos objetos, os autores adotaram técnicas tradicionais de processamentos de imagens, como por exemplo, filtragem e detecção de borda, de forma a tornar o trilho mais evidente e, em seguida, aplicaram a Rede Neural Convolutacional Inception-v3.

Para identificação de placas de trânsito, Preto (2018) utilizou o método de *Deep Learning* (aprendizado profundo) para analisar os *pixels* da imagem e assim classificá-la. O trabalho consistiu na separação de 12 conjuntos de rótulos representados pelos tipos de placas de trânsito. Para arquitetura de Rede Neural Convolutacional foram testados diversas camadas com diferentes parâmetros, sendo que a autora escolheu a de menor tempo de treinamento e com convergências de 100% de acurácia na menor época. O resultado obtido com a CNN atingiu uma 17 correta classificação de 98,7% de todas as imagens de teste, alcançando um ótimo desempenho (PRETO, 2018).

Outra aplicação de Redes Neurais Convolutacionais para detecção de elementos, foi em lavouras de soja, reconhecendo ervas daninhas e classificando-as entre gramíneas e folhas largas. Para o treinamento da Rede Neural foi utilizada a arquitetura *CaffeNet*, disponível na biblioteca Caffe, que consiste de uma replicação da rede AlexNet. Também foram utilizados os algoritmos Máquina de Vetores de Suporte, *AdaBoost* e Florestas Aleatórias em conjunto com uma coleção de extratores de atributos de forma, cor e textura, no intuito de comparar os resultados destas arquiteturas. Nesse trabalho, a

utilização da Rede Neural Convolutacional apresentou uma precisão média superior a 99%, sendo o melhor valor em comparação aos outros algoritmos, além do mais, a CNN tem a vantagem de não necessitar da escolha de bons extratores de atributos, assim como os treinamentos tem um tempo mais viável (FERREIRA, 2017).

Considerando o reconhecimento de alimentos com vista a fornecer o índice glicêmico, Januário, Guedes e Silva (2020) elaboraram uma arquitetura de Rede Convolutacional inspirada no modelo canônico VGG-16, a qual foi preparada para realizar duas tarefas de classificação, sendo a primeira de frutas, com uma base de dados de 65.429 imagens, divididas em 95 classes, e a segunda de alimentos em geral, utilizando 16.643 amostras com 11 classes. Os melhores resultados obtidos denotaram uma acurácia de 98,22% na primeira tarefa e 84,30% na segunda.

Juraszek (2014) utilizou três técnicas para reconhecimento de produtos (guitarra, cafeteira, computadores, etc), são elas BOVW (*Bag of Visual Words*), Redes Neurais Convolutacionais (CNN), treinada pelo autor, e uma CNN previamente treinada como descritor natural na extração de características. Os melhores resultados foram alcançados com as seguintes técnicas: Rede Neural Convolutacional, com uma acurácia de 71%, e a Rede Neural Convolutacional como descritores naturais que apresentou uma acurácia de 90,55%.

Já Vargas, Paes e Vasconcelos (2016) propuseram, em seu artigo, uma comparação entre três métodos utilizados para detecção de pedestres. As duas primeiras técnicas, *Features de Haar* com classificador *AdaBoost* e Histograma de 18 Gradientes Orientado (HOG) com classificador SVM (*Support Vector Machine*), foram utilizadas por Dalal e Triggs (2005); e a terceira, CNN, foi utilizado por Hosang et al. (2015). Foram realizadas neste trabalho análises nos resultados de cada técnica a partir de comparações de variáveis como sensibilidade e especificidade, falsos positivos e negativos e precisão e acurácia. Neste artigo, foi comprovado que a CNN apresentou a melhor solução (VARGAS; PAES; VASCONCELOS, 2016).

3 FUNDAMENTAÇÃO TEÓRICA

Nesta seção faremos um descrição das teorias utilizadas no desenvolvimento deste trabalho

3.1 Embarcação e seus tipos de acordo com a NORMAM

As Normas de Autoridade Marítima (NORMAM) foram criadas pela Marinha do Brasil para assegurar a proteção do meio ambiente e a segurança da navegação, e é esclarecido diversos conceitos, métodos, documentos, relatórios, permissões e obrigatoriedades. De acordo com as Normas, a embarcação é definida como qualquer construção que flutue, inclusive as plataformas flutuantes, sendo fixas ou não, sendo possível a locomoção na água, por meios próprios ou não, transportando pessoas ou cargas.

Sabendo o que é uma embarcação, é também possível caracterizá-la conforme o seu tipo. Há vários tipos descritos nas normas, como por exemplo consta no anexo A, porém neste trabalho foram utilizados 6 (seis), que são:

- **Canoa**

Canoa é toda pequena embarcação a remos de formato afilado, com popa fechada, região extrema a ré, em painel e não dotada de leme, Figura 1.

Figura 1: Canoa



Fonte: MATUETE (2021)

- **Catamarã**

Neste caso, o catamarã também pode ser classificado como Multicasco, pois é constituído de dois cascos paralelos ligados por uma estrutura rígida, Figura 2. Dokkun (2013a) descreve o catamarã como uma embarcação interessante, pois esta consegue combinar muito espaço com pouco arrasto hidrodinâmico.

O autor ainda descreve o casco, invólucro exterior da embarcação, como um tipo que possui uma alta estabilidade devido a flutuabilidade ser encontrada em ambos os lados.

Figura 2: CAT BAM I da empresa Rodofluvial Banav



Fonte: BANAV (2016)

- **Ferry Boat**

Embarcação destinada ao transporte de carga e passageiros, Figura 3.

Figura 3: Ferry Boat



Fonte: G1 (2021)

- **Iate**

Embarcação de esporte e/ou recreio com comprimento igual ou superior a 24 metros, Figura 4.

Figura 4: Iate



Fonte: Estadão (2017)

- **Navio de Guerra**

Embarcações que podem ser empregadas durante a guerra, são utilizadas pelas forças armadas, Figura 5.

Figura 5: Navio de Guerra Solimões (V-24)



Fonte: WIKIPÉDIA (2021)

- **Veleiro**

Embarcação propelida por um velame (Conjunto de velas de tecido de corte e cálculo apropriados) em um ou mais mastros e controlados por um conjunto de cabos chamado cordoalha, Figura 6. Dokkun (2013a), os veleiros se diferem de outras embarcações por apresentar uma larga superfície lateral em relação a dimensão do navio, sendo possível combinar as velas com diferentes tipos de cascos.

Figura 6: Veleiro “Cisne Branco”



Fonte: G1 (2019)

3.2 Segurança da Navegação

Para garantir a segurança de navegação, dentre uma das exigências feitas pela Marinha, seja apresentado o Certificado de Segurança da Navegação (CSN), que é emitido para uma embarcação atestar que as vistorias previstas nas normas foram realizadas. As Sociedades Classificadoras (SC) são organizações reconhecidas com Delegação de Competência estabelecida pela NORMAM 06 (MARINHA, 2017), a qual se refere ao Reconhecimento de Sociedades Classificadoras e Certificadoras (Entidades Especializadas) para Atuarem em Nome do Governo Brasileiro.

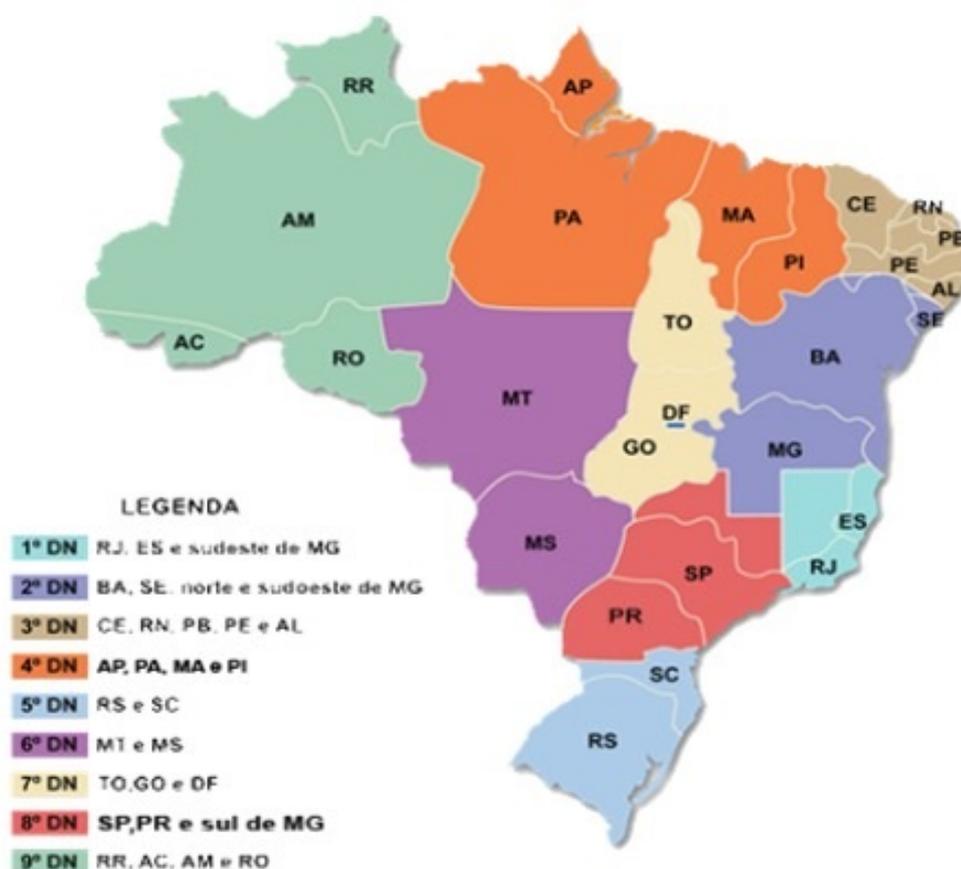
De acordo com a NORMAM 06 (MARINHA, 2017), as sociedades e certificadoras implementam e fiscalizam conforme os requisitos de Convenções e Códigos Internacionais ratificados pelo Brasil e Normas Nacionais, relativas a segurança da navegação, salvaguarda da vida humana e prevenção da poluição.

Porém, apesar da vistoria, fiscalização e cumprir com todas as documentações e exigências estabelecidas pela NORMAM (MARINHA, 2017), não há garantia da segurança de uma embarcação, visto que há outras variáveis que podem levar ao acidente, quanto a tripulação, posição da carga, obstáculos em rios, negligência quanto a capacidade de carga e passageiros.

As informações quanto a ocorrência de acidentes marítimos, foram obtidas do

Inquérito Administrativo sobre Acidentes e Fatos da Navegação (IAFN) fornecidas pela Marinha do Brasil (MB). Para que haja uma melhor administração em todo o Brasil, a Marinha dividiu o território em Distritos Navais (DN), os quais são responsáveis por determinados estados. Os distritos navais são nove e estão divididos da seguinte maneira, conforme Figura 7.

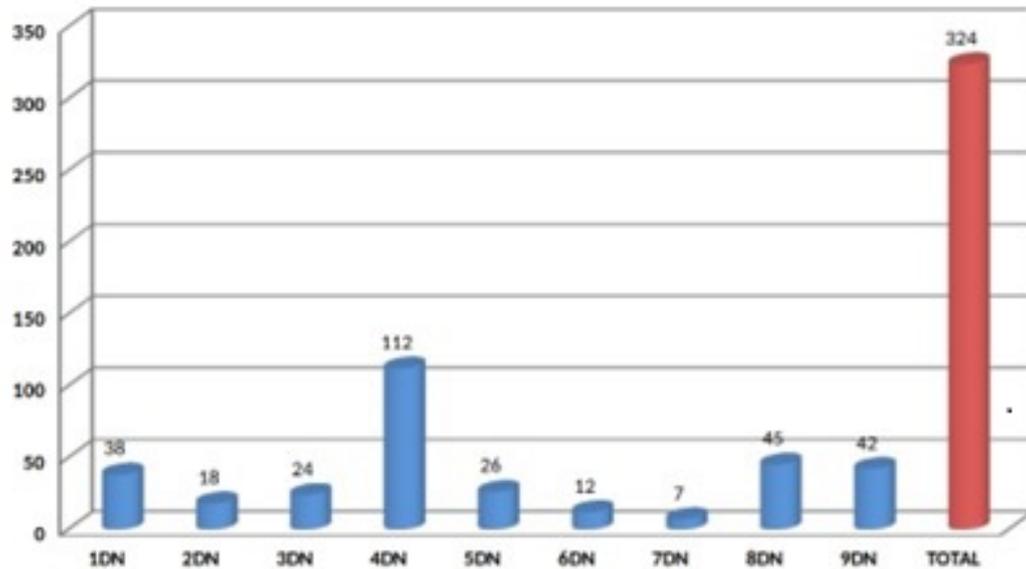
Figura 7: Distribuição territorial dos Distritos Navais



Fonte: marinha.mil.br (2021)

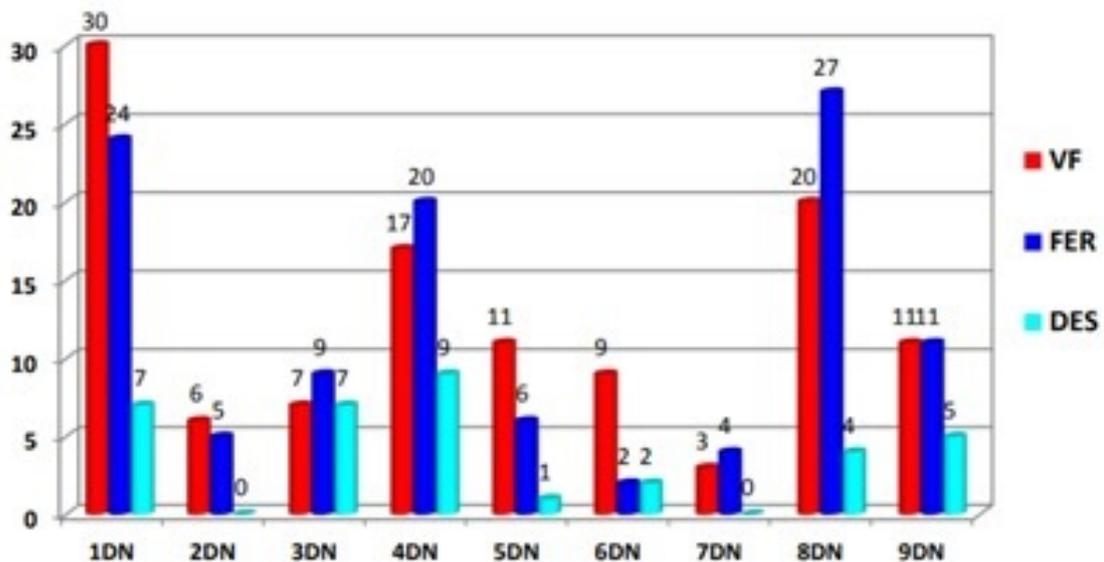
Nas Figuras 8 e 9, retrata dados obtidos do IAFN no ano de 2020 e de 2021, sendo este ter dados coletados até 31 de julho, sobre a quantidade de Vítimas Fatais (VF) e Desaparecidos (DES), Feridos (FER), por Distrito Naval (DN).

Figura 8: VF/DES por DN



Fonte: IAFN (2020)

Figura 9: Vítimas Fatais (VF), Desaparecidos (DES) e Feridos (FE) por DN



Fonte: IAFN (2021)

O que abrange a região é o 4º distrito naval e pode-se observar na Figura 8, que cerca de 34% das ocorrências pertencem a esse distrito, estando em 1º lugar em 2020. Os principais tipos de embarcações que sofreram os acidentes, conforme Anexo A, são: Barco, lancha e canoa. E na Figura 9, estando em 3º lugar, os principais acidentes, conforme Anexo B, são: Barco, Lancha e Empurrador com Balsa. Sendo o Barco os tipos

de embarcação regional feito de madeira.

Quanto a natureza do acidente, existem diversas classificações, porém, será abordado neste trabalho o naufrágio. Pois evitando o naufrágio, conseqüentemente, reduzirá as vítimas fatais, desaparecidos e feridos.

3.3 Estabilidade

Segundo Cabral (1979), a estabilidade pode ser definida como sendo uma propriedade que o navio tem de se manter em uma posição estável ou com tendência a retornar a esta posição, quando por motivos externos tenha sido alterado. Para se entender como funciona a estabilidade é necessário entender alguns conceitos, como: Princípio de Arquimedes, Momento e o Centro de Gravidade (CG).

3.3.1 Princípio de Arquimedes

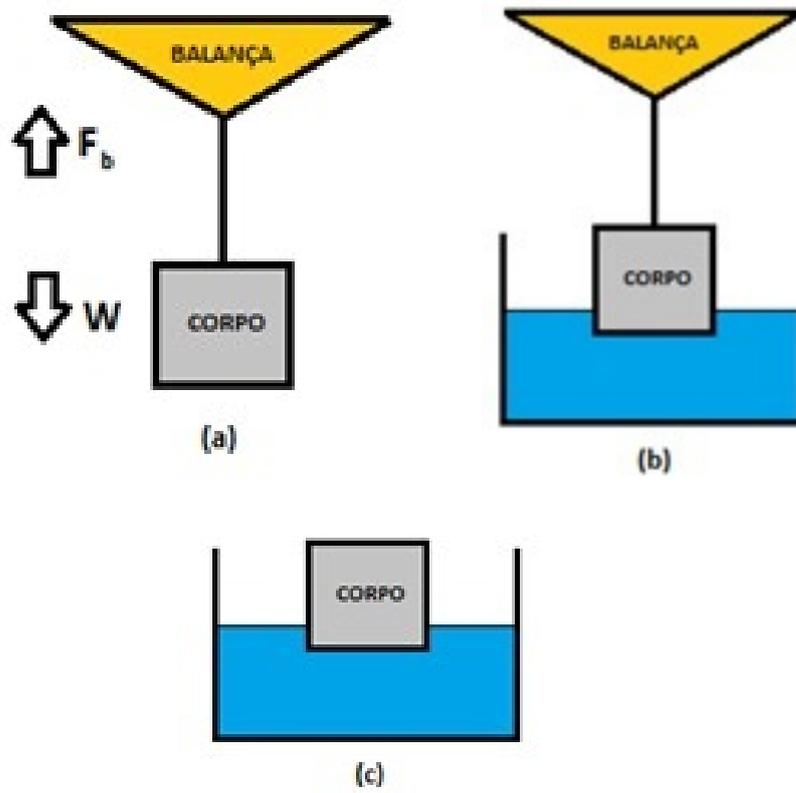
De acordo com a primeira lei de Newton, todos os corpos na terra estão sobre a ação de forças, por exemplo a força do próprio peso, e que a somatória de todas essas forças é igual a 0.

$$\sum_{i=1}^n F_i = F_1 + F_2 + F_3 + \dots + F_i \quad (1)$$

$$\sum_{i=1}^n F_i = 0 \quad (2)$$

Com base nisso, o princípio de Arquimedes afirma que quando um corpo é imerso em um líquido, sofre a ação de uma força vertical igual ao peso do líquido deslocado, esta ação é denominada de força de empuxo ou simplesmente de empuxo do corpo. É possível observar esse princípio no exemplo dado por Zubaly (2011), Figura 10:

Figura 10: Princípio de Arquimedes



Autoria Própria (2021)

Inicialmente em (a) o objeto não sofre nenhuma influência da força de empuxo, apenas da força da balança (F_b) que é igual ao seu próprio peso (W). Quando começa a colocar no meio fluido, Figura 10, a força de empuxo (E) começa a aparecer, gerando assim uma força contrária a força peso, somando com a força da balança que ainda está presente neste momento, resultando em

$$\sum_{i=1}^n F_i = F_b + E - W \quad (3)$$

Logo, resolvendo a equação, pode-se determinar que a força da balança é igual a diferença das forças peso e empuxo, conforme as Equações 4 e 5:

$$0 = F_b + E - W \quad (4)$$

$$F_b = E - W \quad (5)$$

Por fim, ao se colocar o objeto no fluido por completo, Figura 10, e assim atingindo o equilíbrio (c), temos que a força peso se igualou com a força de empuxo, resultando:

$$\sum_{i=1}^n F_i = E + W, \quad (6)$$

$$E = -W, \quad (7)$$

como o empuxo (E) é definido como

$$E = \rho g V, \quad (8)$$

onde, ρ é a densidade do fluido, g é a aceleração da gravidade e V é o volume do cilindro. Portanto, podemos concluir que:

$$W = \rho g V, \quad (9)$$

onde, W é o peso do objeto, ρ é a densidade do fluido, g é a aceleração da gravidade e V é o volume deslocado pela água.

3.3.2 Momento

Cabral (1979) explica que para saber o momento (M) de uma força (F) em relação a um eixo, o produto do valor absoluto da força pela distância (b) da sua linha de ação ao eixo é dado por:

$$M = Fb(Nm), \quad (10)$$

3.3.3 Centro de Gravidade dos objetos

Segundo Cabral (1979), o centro de gravidade (G) de um corpo é o ponto no qual se pode assumir toda a sua massa concentrada, ou seja, o ponto de aplicação da resultante das forças da gravidade que sobre este atuam. Sendo assim, o G é o ponto de equilíbrio em que a combinação de todos os momentos se anula. Expressando em uma equação temos:

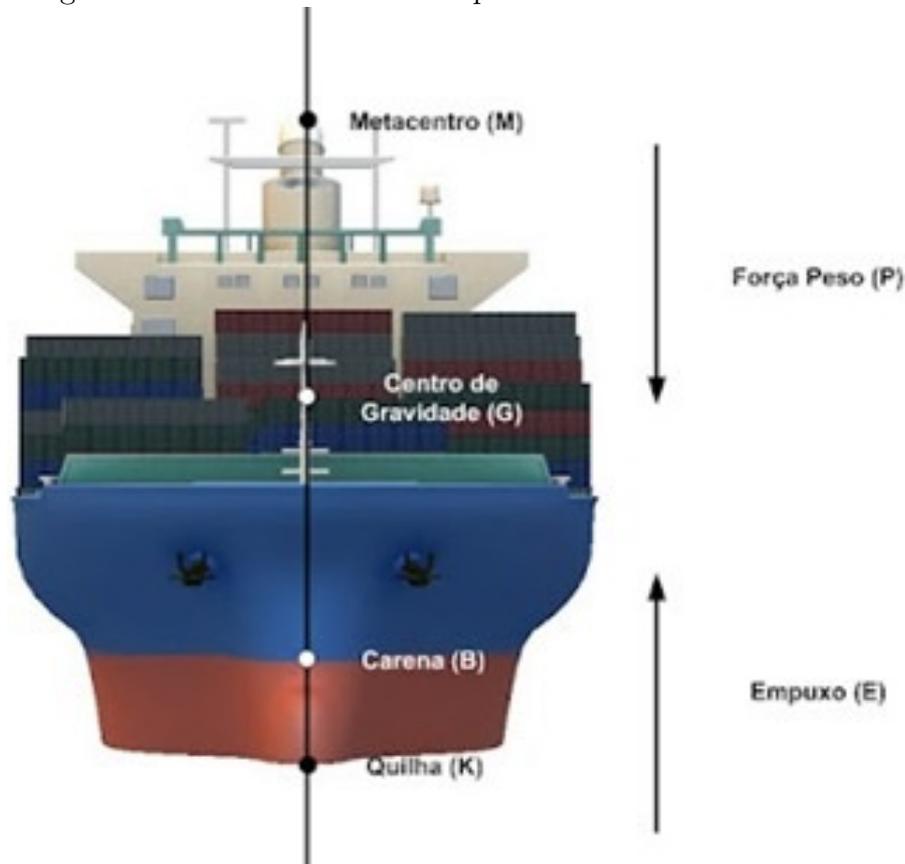
$$\sum_{i=1}^n d_i = \frac{\sum_{i=1}^n P_i d_i}{\sum_{i=1}^n P_i}, \quad (11)$$

onde d é a distância do centro de gravidade, P é o peso do corpo e i é o índice do corpo. Portanto, a partir da Equação 11 é possível obter o G de um ou mais corpos em um mesmo sistema.

3.3.4 Estabilidade Transversal

Segundo Cabral (1979), a Estabilidade Transversal de um navio é um meio de avaliar a navegabilidade do navio através das forças transversais exercidas, sendo estes: Centro de Gravidade (G), o Centro de Carena ou Empuxo (B), que é o centro de gravidade do volume de água deslocada, ou seja, é o ponto de aplicação da força de empuxo, e o Metacentro (M), um ponto virtual onde o navio encontra-se suspenso, Figura 11. O ponto de referência K , representa a quilha do navio, o ponto de interseção entre a linha de centro e a linha de base do navio. (Zubaly, 2011).

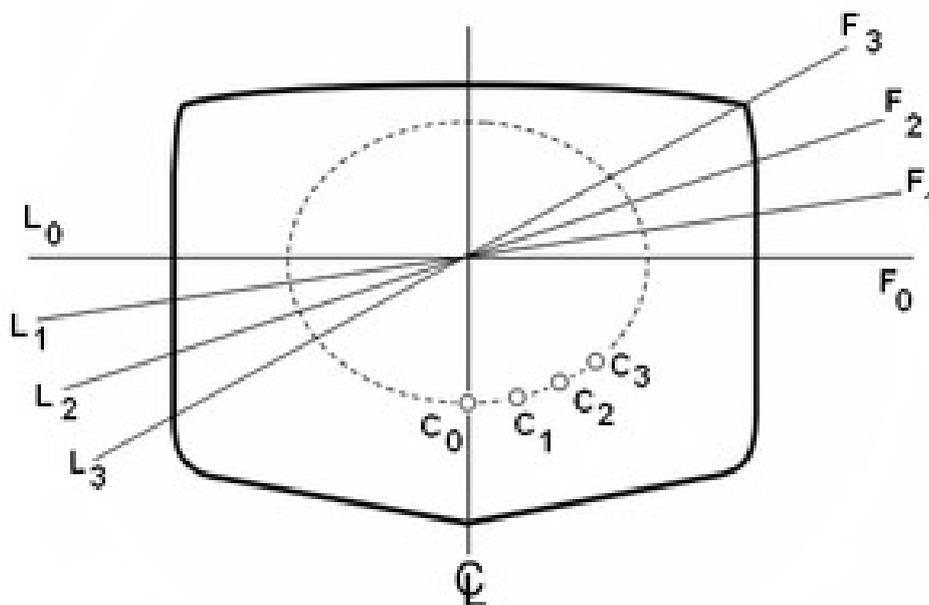
Figura 11: Pontos de referência para Estabilidade Transversal



Fonte: Lucena (2018)

O Metacentro (M) é determinado pela interseção da linha reta na vertical que passa por B e da linha reta vertical que passa pela nova posições de B devido a inclinação do navio, conforme a Figura 12. (CABRAL, 1979); (DOKKUM, 2013).

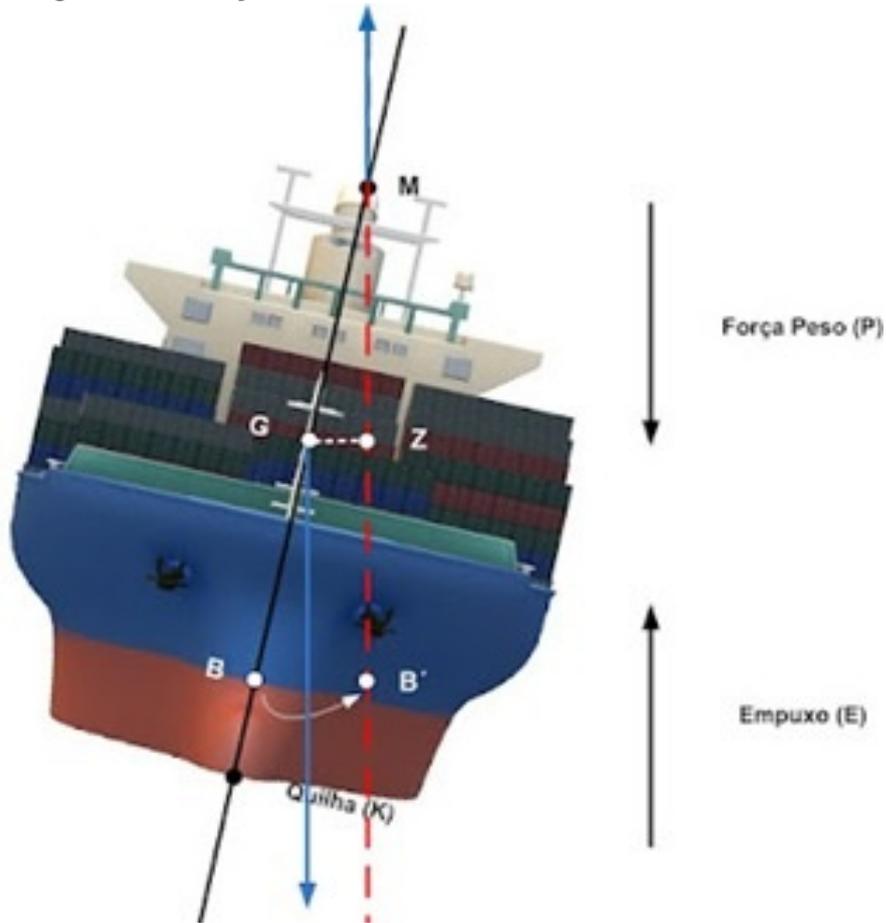
Figura 12: Localização do Centro de Carena em diferentes inclinações



Fonte: Wikipédia (2019)

Coincidentemente, o KG é a altura vertical do centro de gravidade (G), KB é a altura vertical do centro de carena (B). O Braço Metacêntrico (KM) é determinado quando o navio é inclinado a um pequeno ângulo θ , que consequentemente acaba gerando novas posições para K , B e G , conforme Figura 13.

Figura 13: Posição das referências em um navio inclinado



Fonte: Lucena (2018)

Para se determinar o KM , pode-se utilizar a seguinte fórmula:

$$KM = KB + BM \quad (12)$$

Dokkun (2013b) determina que o raio metacêntrico (BM), cujo o valor é a distância do centro de carena (B) para o metacentro (M), pode ser obtido pela equação:

onde I é o momento de inércia lateral da área da linha d'água e V o volume do casco, deslocamento.

3.3.5 Braço de Endireitamento

O braço de endireitamento (GZ) é uma das características mais importantes avaliada para determinar a estabilidade de um navio. Representa a menor distância perpendicular

do ponto do centro de gravidade (G) para o novo eixo gerado devido a inclinação, Figura 13. (CABRAL, 1979); (DOKKUN, 2013b)

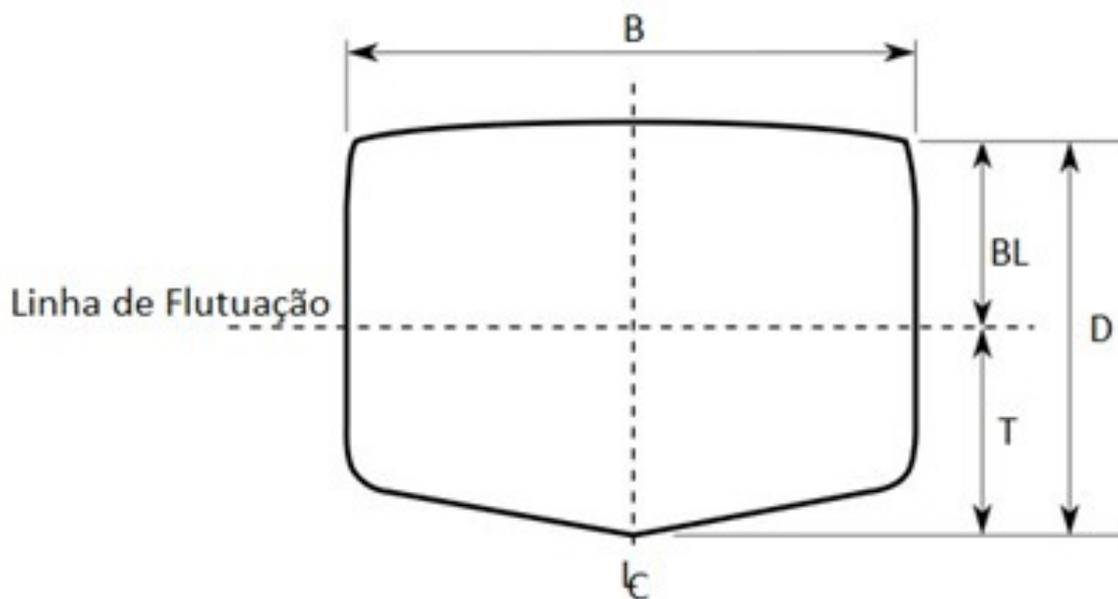
Dokkum (2013) determina que o valor de GZ possa ser obtido da seguinte forma:

$$GZ = KM \sin \theta \quad (13)$$

onde θ é o ângulo formado entre os eixos. Aplicando a equação para cada ângulo de inclinação do navio, é possível obter uma curva e gerar um gráfico para analisar a estabilidade.

A borda livre, conforme Dokkum (2013b), é uma das principais formas de avaliar a estabilidade de uma embarcação, pois sabendo que esta não atingindo o mínimo determinado pela NORMAM 02 (MARINHA, 2005), corre alto risco de acontecer um acidente por instabilidade.

Figura 14: Seção Transversal do Navio



Fonte: Wikipédia (2021)

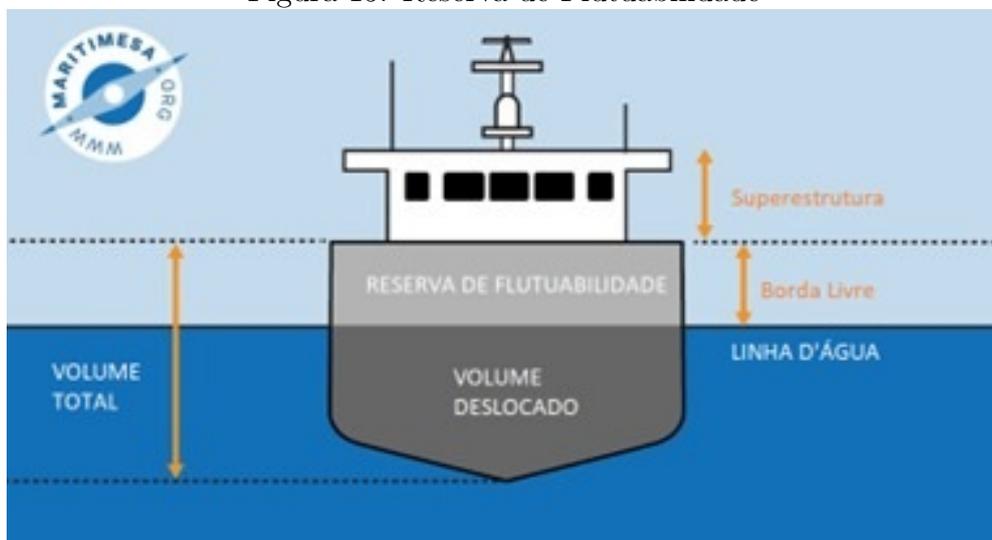
Para avaliar melhor a borda livre, é importante também saber alguma das principais medidas transversais de navio, Figura 14, que são:

- **Boca (B)** - medida entre as extremidades laterais.
- **Pontal (D)** - medida entre a quilha e o convés principal.

- **Calado (T)** - distância entre o fundo e a linha d'água.
- **Borda Livre (BL)** - distância entre a linha d'água e o convés principal.

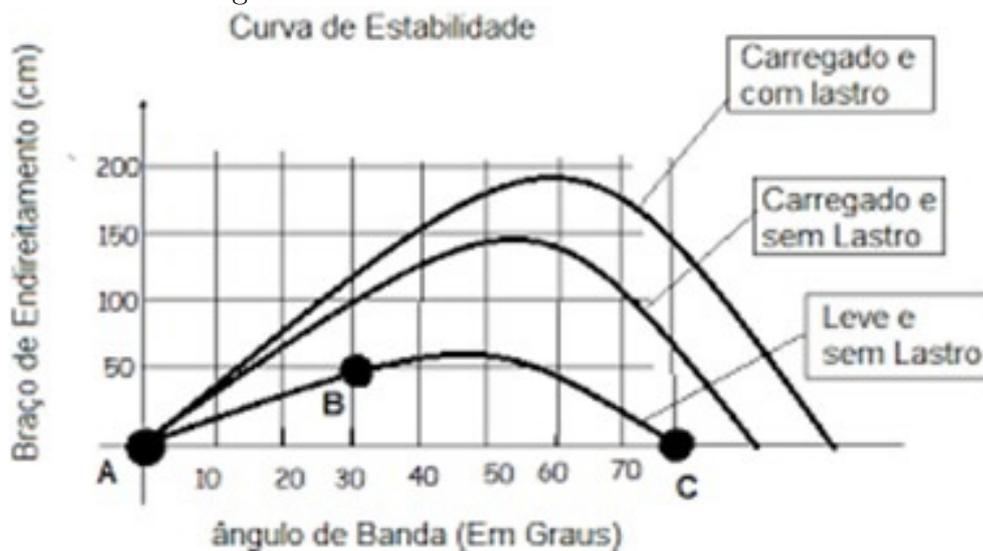
Conforme a Figura 15, é possível observar a reserva de flutuabilidade, a qual é afetada de acordo com o carregamento do navio. Enquanto na Figura 16, observa-se o comportamento gráfico do braço de endireitamento (GZ) x ângulo de inclinação θ devido a quantidade de carga embarcada.

Figura 15: Reserva de Flutuabilidade



Fonte: maritimesa.org (2020)

Figura 16: Gráfico das curvas de estabilidade

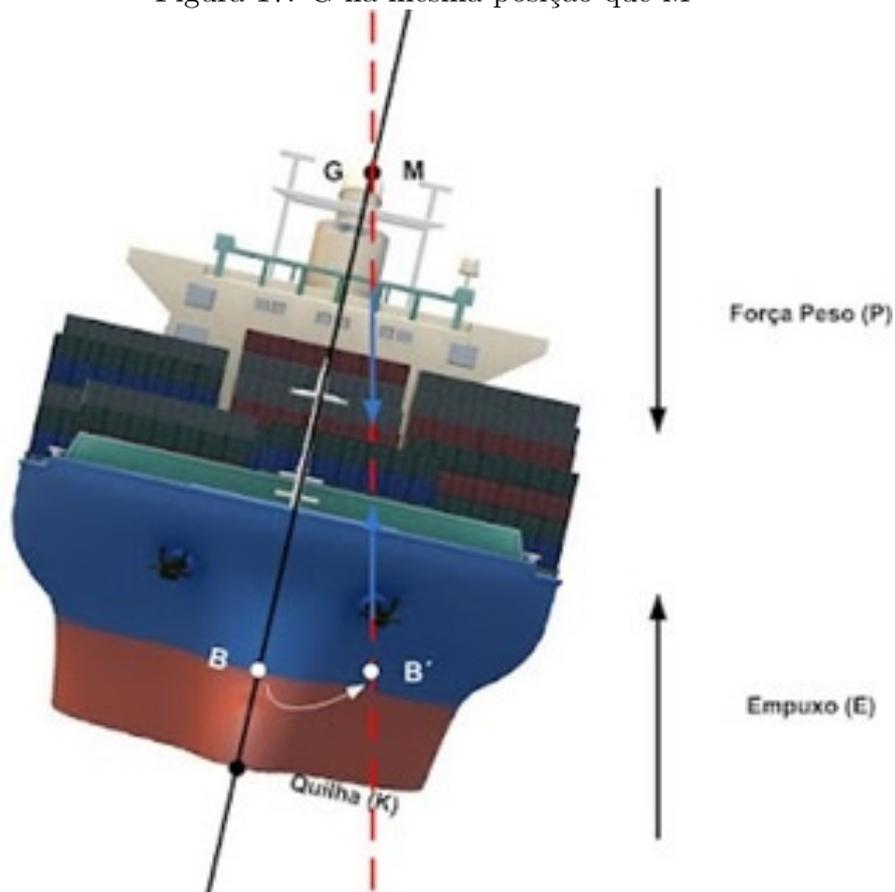


Fonte: IFPB (2013)

Como foi visto sobre Segurança da Navegação, uma das causas de acidentes é a posição e o excesso de passageiro e carga. De acordo com a equação 11 pode-se concluir que o centro de gravidade sofre influência do peso do objeto, o que significa que se houver um peso relativamente alto em relação ao peso total em um dos bordos, extremidade lateral do navio, pode causar um efeito chamado de adernamento, onde o navio fica inclinado. Para isso, a solução é que seja feito a redistribuição de passageiros e cargas.

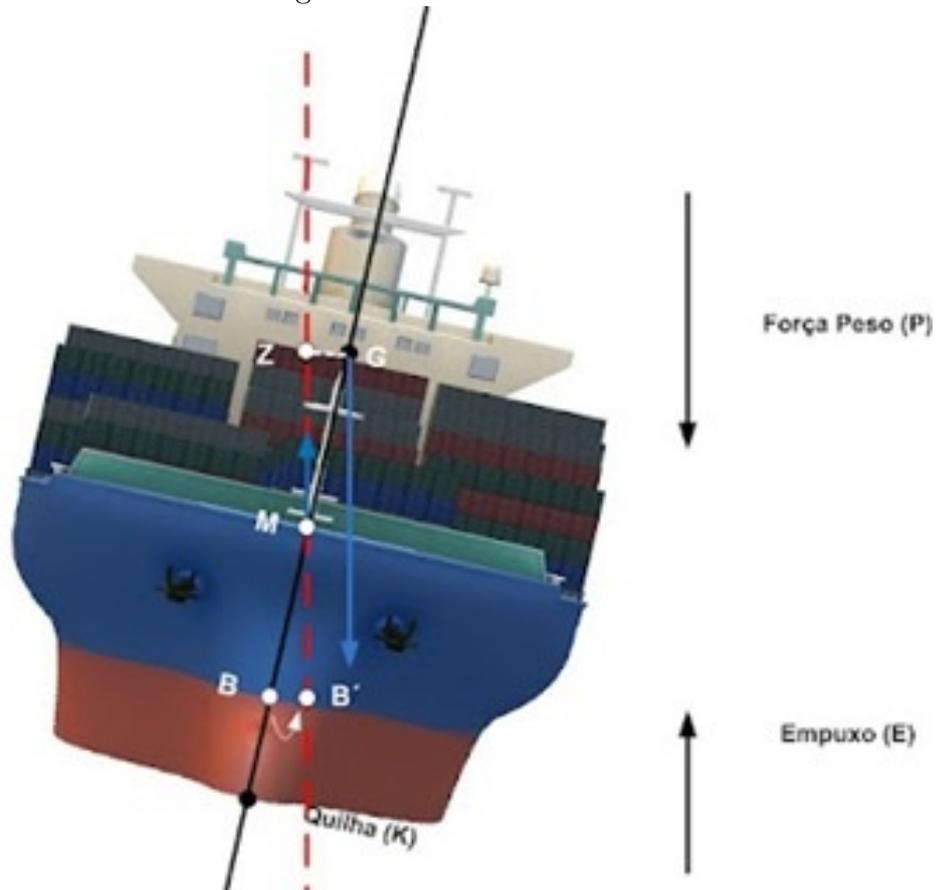
A posição vertical dos passageiros e cargas também influenciam no centro de gravidade do sistema. Conforme a Figura 17, onde mostra que a carga estaria no fundo do navio, mantém o G abaixo do M, gerando estabilidade, enquanto na Figura 18, mostra que o G está na mesma direção do M, podendo gerar adernamento ou até mesmo emborcamento, situação em que o navio vira por completo.

Figura 17: G na mesma posição que M



Fonte: Lucena (2018)

Figura 18: G acima de M

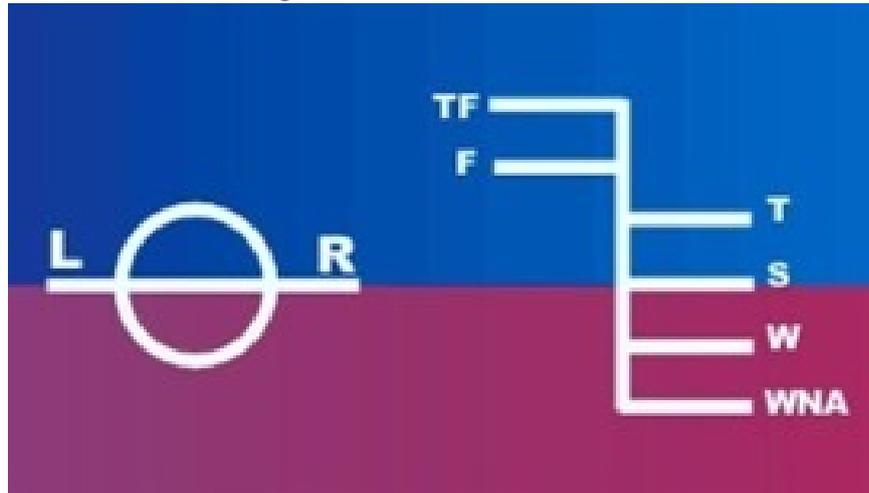


Fonte: Lucena (2018)

3.4 Disco de Plimsoll

Segundo a NORMAM (MARINHA, 2005), existem marcas de linha de carga as quais ficam em ambos os bordos da embarcação, também conhecido como Disco de *Plimsoll*, em homenagem ao negociante em 1984 que adotou os discos na embarcação. Estes discos auxiliam na indicação do quanto a embarcação pode ser carregada sem prejudicar a estabilidade, Figura 19.

Figura 19: Disco de Plimsoll



Fonte: Google Imagens (2022)

Na Figura 19 também é possível observar duas letras acima da linha horizontal que atravessa o disco, que representam a sigla da certificadora ou classificadora. O anel possui 180 mm de diâmetro externo cruzado por uma linha horizontal de 300 mm de comprimento e ambos com 25 mm de largura, sendo a face. Ao lado direito do disco é possível observar algumas letras, as quais significam:

- **TF (Tropical Fresh Water)** - Água doce tropical.
- **F (Fresh Water)** - Água doce.
- **T (Tropical)** - Água Salgada Tropical.
- **S (Summer)** - Água Salgada no Verão.
- **W (Winter)** - Água Salgada no Inverno.
- **WNA (Winter North Atlantic)** - Água Salgada, Atlântico Norte no Inverno.

Vale ressaltar que essas medidas variam conforme a área de navegação e o material da carga transportada não seja de madeira.

Segundo Lacerda (2015), para definir a posição do limite máximo de carga e do calado carregado vai depender do formato do casco, das características hidrostáticas, da localização do ponto de alagamento, da condição de estanqueidade, do estudo de estabilidade e do cálculo estrutural.

Para este trabalho foram analisadas 3 condições as quais são: Leve (Figura 20) para embarcações que estejam com pouca ou sem carga a bordo; Carregado (Figura 21) para embarcações que estejam com 100% carregados para operação; Sobrecarregado (Figura 22) para embarcações que estejam com carga além da sua capacidade de operação, sendo este último uma condição rara de ser observada, para isso foi necessário criar uma imagem sintética.

Figura 20: Leve



Fonte: Google Imagens (2022)

Figura 21: Carregado



Fonte: Google Imagens (2022)

Figura 22: Sobrecarregado

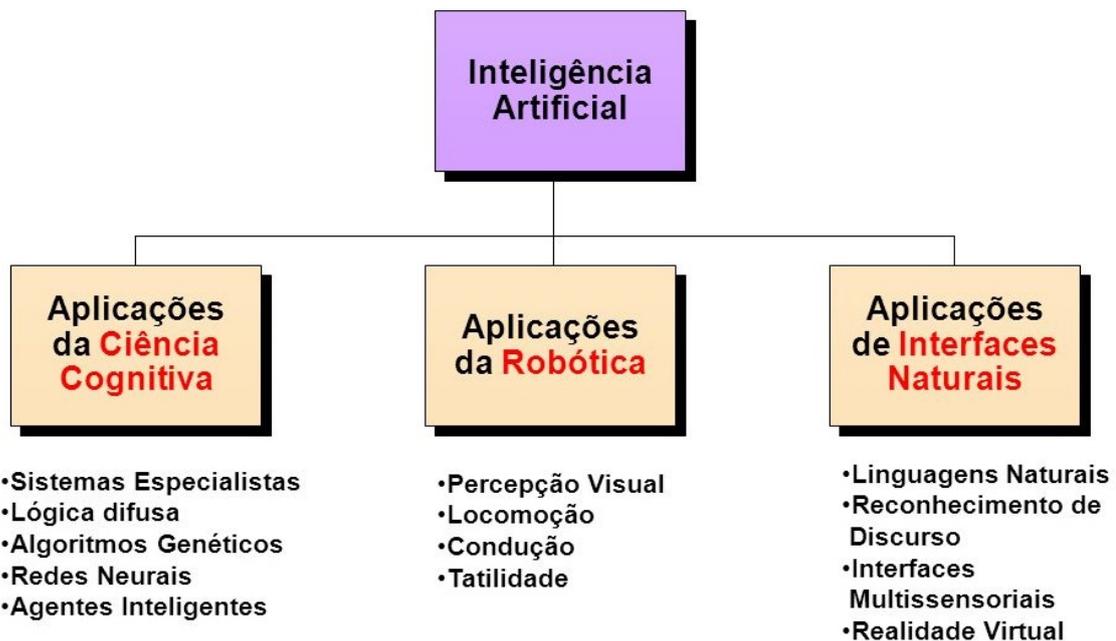


Fonte: Google Imagens (2022)

3.5 Inteligência Artificial (IA)

Siegel *et. al.* (2018) explica que Inteligência Artificial é uma das áreas da ciência da computação que foca na construção de máquinas e computadores capazes de simular um tipo de comportamento inteligente, possibilitando realizar tarefas semelhantes a de seres humanos, como reconhecimento de voz, tomada de decisão, percepção visual, tradução de idiomas.

Figura 23: Áreas de aplicação da Inteligência Artificial



Fonte: Menezes (2018)

Na Figura 23 é possível observar as diversas áreas que há aplicação de inteligência artificial.

3.6 Machine Learning (ML)

Alan Turing foi o pioneiro da área de *Machine Learning (ML)*, por exemplo, no artigo publicado em 1950, propôs um tipo de jogo, o qual é chamada de “O Jogo da Imitação – The Imitation Game”, também conhecido como o Teste de Turing, a qual possui três participantes: Homem (*A*), Mulher (*B*) e o Juiz (*C*). O juiz precisa determinar quem é a mulher e quem é homem, porém a condição é que ele não tenha contato com nenhum dos dois, logo, ele precisa elaborar perguntas para saber quem é quem.

A proposta por Alan Turing é de substituir um dos participantes por uma máquina durante o jogo e imitar algum dos gêneros. O objetivo não é confundir o Juiz quanto ao “gênero” da máquina, mas sim de fazê-lo duvidar sobre as repostas se são de uma máquina ou de uma pessoa.

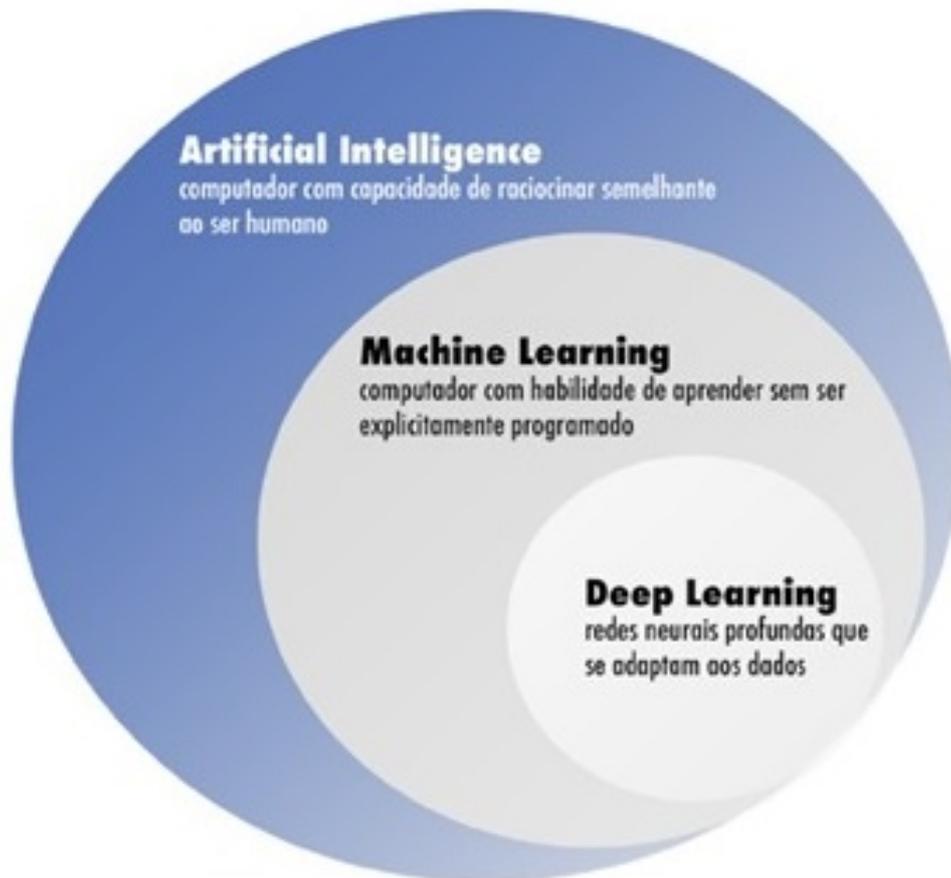
Para Bishop (2006) e Almeida (2019), *ML* é um tipo de sistema capaz de adquirir e acumular conhecimento e assim melhorar a performance em tarefas específicas. São programas desenvolvidos para aprender a fazer previsões sem ter a supervisão de um programador. Esse tipo de técnica é aplicado em diversas áreas, como processamento de imagens, recomendações de música, detecção de fraude.

3.6.1 Deep Learning (DL)

Deep Learning (DL) é construído sobre redes neurais, sendo um tipo de *machine learning* que se assemelha aos neurônios do ser humano, Figura 25. É possível trabalhar com análise de dados brutos, propiciando a classificação de informações em diferentes formatos, como reconhecimento de áudio, imagens. *Deep Learning* são métodos que permitem que modelos computacionais de múltiplas camadas de processamento que aprendem com representações de dados com múltiplos níveis de abstração. (LeCun *et. al.* 2015).

Na Figura 24 mostra-se a relação, na forma de conjunto (subgrupos), de *IA*, *ML* e *DL*.

Figura 24: Subgrupos da Inteligência Artificial



Fonte: Menezes (2018)

Anjos (2019) afirma que quanto mais profunda, ou mais níveis, há em uma rede neural, maior a quantidade de operações e conseqüentemente uma necessidade de um poder computacional maior. Segundo Neto (2019), os modelos de *deep learning* são conhecidos também como redes neurais devido aos primeiros algoritmos criados para representar o aprendizado biológico, assemelhando-se ao cérebro.

3.6.2 Rede Neurais Artificiais (RNA)

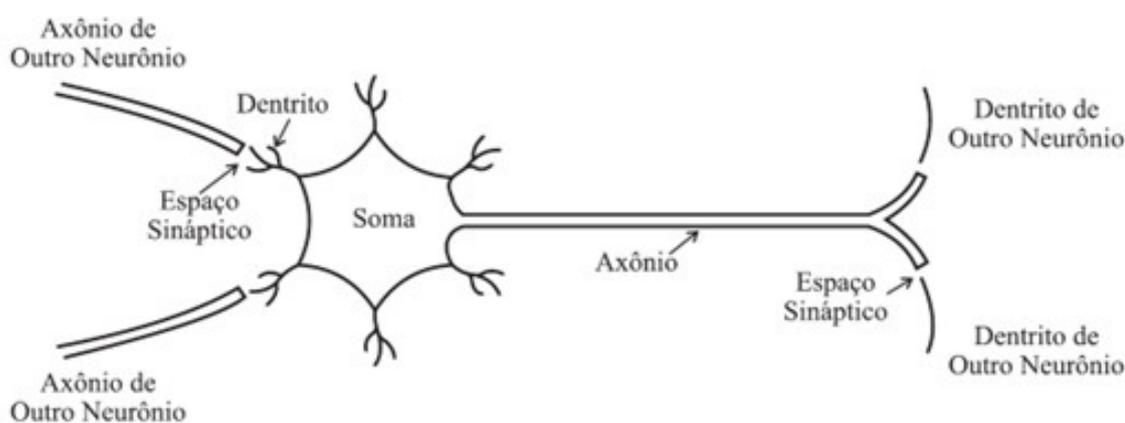
Furtado (2019) menciona que um dos primeiros trabalhos voltados para Redes Neurais foi elaborado por McCulloch e Pitts sugerindo, em 1943, que houvesse uma construção de uma máquina baseada no cérebro humano. Em 1949 Donald Hebb, autor de “A Organização do Comportamento” foi o primeiro a propor uma lei de aprendizagem para as sinapses dos neurônios.

Em 1951 foi construído o Snark, primeiro neuro computador feito por Mavin

Minsky, porém nunca processou informação interessante, porém serviu de base para o desenvolvimento de outras ideias sobre o assunto. Entre 1957 e 1958 surgiu o primeiro computador a obter sucesso (Mark I Perceptron), criado por Frank Rosenblatt, Charles Wightman e outros, motivados pela ideia de criar um sistema que reconhecesse padrões.

Para se entender como funciona a Rede Neural Artificial, é necessário entender um pouco do cérebro humano. Este pode identificar imagens, sons, padrões através de estímulos gerados pelo meio externo. Por trás dessa ação e reação da pessoa em relação ao meio, existe uma sequência de processos que ocorrem nos neurônios. Conforme Moreira (2017), os neurônios biológicos, representado pela Figura 25, são constituídos basicamente de dendritos, corpo celular e axônio:

Figura 25: Neurônio Biológico Genérico

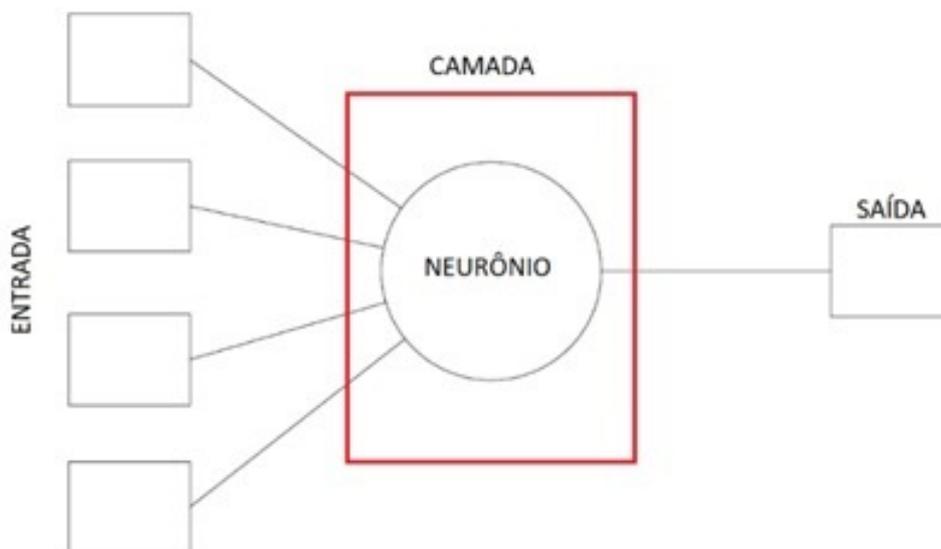


Fonte: Adaptado de Fausset (1994, p.6)

Os dendritos (a) são responsáveis por receber estímulos provenientes de outros neurônios ou de células sensoriais, ajustando os impulsos provenientes de outros neurônios. O corpo celular (b) contém o núcleo, onde ocorre a síntese proteica. No axônio (c) é transmitido os impulsos nervosos provenientes do corpo celular, enquanto nas terminações do axônio (d) é onde contém as sinapses, que estabelecem comunicação com os dendritos ou corpos celulares de outros neurônios (Moreira, 2013).

A partir disso foi desenvolvido um sistema que imitasse os neurônios biológicos, chamados de neurônios artificiais, como representado na Figura 26.

Figura 26: Neurônio Artificial



Fonte: Autoria Própria (2021)

Um exemplo de uma rede neural com mais de uma camada, é o do autor Menezes (2018), Figura 27. A figura representa as etapas de uma rede neural, sendo:

- **Treinamento:** em que durante esta fase, a rede neural é alimentada com um banco de dados (Dataset) contendo milhares de imagens rotuladas de diversas classes fazendo com que a rede aprenda a classificar cada uma.
- **Entrada:** Fornecimento de uma imagem para a RNA treinada.
- **Primeira camada:** Os neurônios respondem as características simples, como borda e textura.
- **Camada mais altas:** Neurônios respondem a estruturas mais complexas nas camadas seguintes.
- **Última camada:** Os neurônios respondem a conceitos mais complexos e abstratos, o que seria identificado como objetos reais.
- **Saída:** A RNA prevê a imagem de entrada.

Figura 27: Rede Neural Artificial



Fonte: Menezes (2018)

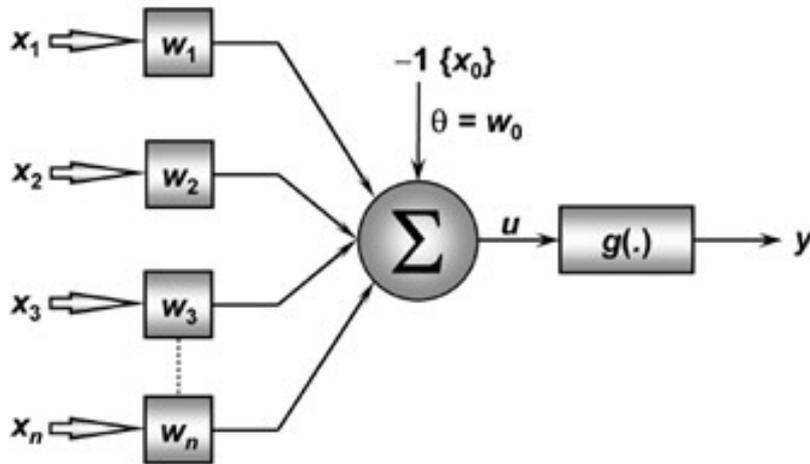
De acordo com Furtado (2019) pode-se observar que os dados de entrada são os atributos, que são ajustados com determinados pesos e passam pela camada que contém o neurônio, e por fim gerando os dados de saída. Este é um exemplo de uma Rede Neural Artificial (RNA) de camada simples com um neurônio, também chamada de Perceptron, entretanto existem modelos que podem ter duas ou mais camadas e mais de dois neurônios cada.

3.6.3 Perceptron

Perceptron, idealizado por Rosenblatt (1958), é a forma mais simples de configuração de uma RNA. A simplicidade da rede é devido conter apenas uma camada neural e somente um neurônio artificial (Silva, 2019), conforme a Figura 28, e definido pelas equações 14.

$$\begin{cases} \mu = \sum_{i=1}^n w_i x_i - \theta \\ y = g(\mu) \end{cases} \quad (14)$$

Figura 28: Perceptron

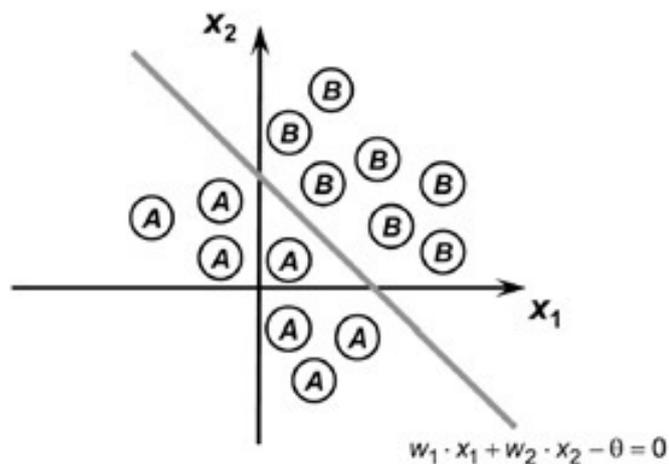


Fonte: Silva (2019)

Onde x_i são as entradas da rede, w_i são os pesos associados às respectivas entradas, θ é o limiar de ativação, $g(\cdot)$ é a função de ativação e μ é o potencial de ativação. Como é uma rede simples, os valores de saída são binários, ou seja, os valores são 0 ou 1 se for considerado a função de ativação degrau ou -1 e 1 se for assumido a função de degrau bipolar. (Silva, 2019)

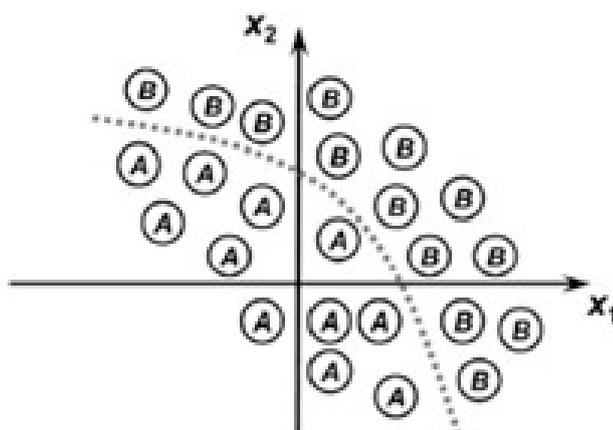
O perceptron consegue gerar soluções para problemas linearmente separáveis, figura 29, visto que a função da equação 14 é de primeiro grau. Porém, essa rede não se adequa em situações em que os problemas não são linearmente separáveis, Figura 30.

Figura 29: Solução linearmente separável



Fonte: Silva (2019)

Figura 30: Solução linearmente não-separável



Fonte: Silva (2019)

De acordo com Rocha (2018), o perceptron apresenta limitações quanto para solucionar problemas que não são linearmente separáveis, então para contornar isso seria necessário adicionar mais camadas, tornando assim, uma Rede Perceptron de Múltiplas Camadas.

3.6.4 Função Softmax

A função softmax, conforme o Autor Nwankpa (2021), é um dos tipos de função de ativação utilizada em redes neurais. O objetivo desta função é calcular a distribuição de probabilidade de um vetor de número real, equação 15, produzindo uma saída entre 0 e 1, sendo a soma de todas as probabilidades igual a 1.

$$f(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (15)$$

onde x é designado o vetor de neurônio de saída, i representa o índice do neurônio de saída e j representa todos os neurônios de uma determinada camada. Nwankpa (2021) afirma que a função *Softmax* é bastante utilizada em modelos multi-classes, onde retorna a probabilidade de todas as classes, com a classe alvo tendo a maior probabilidade. As classes são as saídas de uma RNA, onde se pode ter duas ou mais repostas, não sendo adequada para o *Perceptron*. Neste caso se utilizaria a função *Sigmoid*, em que a principal diferença é que esta é utilizada para classificações binárias.

3.6.5 Entropia cruzada

Rubinstein em 1997 desenvolveu a teoria da Entropia Cruzada (EC), o que demonstrou bastante eficiência para solução de problemas combinatórios complexos. Segundo o Scott (2015), a metodologia de EC é utilizado para determinar o quão similar duas medidas são. Para Oliveira (2016), a teoria pode ser definida em duas fases:

1. Geração aleatória dos dados da amostra de acordo com específico
2. Atualização dos parâmetros do mecanismo para geração da melhor amostra na próxima iteração.

Seguindo um exemplo aplicado por Oliveira (2016), considerando a determinação da probabilidade, θ , do evento raro ψ , a ocorrência é definida como:

$$S(X) \leq \gamma \quad (16)$$

onde $S(X)$ é uma função desempenho de uma determinada amostra aleatória X , γ , $\gamma \in \mathfrak{R}$, sendo o limiar da região de interesse do espaço amostral X sobre $f(\mu)$. $X = (x_1, x_2, \dots, x_n)$ é um vetor N números aleatórios pertencente a X . A expressão da probabilidade θ , a função teste $H(X)$ e o operador indicador I são definidos como:

$$\theta = P_\mu \{S(X) \geq \gamma\} \quad (17)$$

$$H(X) = I \{S(X) \geq \gamma\} \quad (18)$$

$$I \{S(X) \geq \gamma\} = \begin{cases} 1, & \text{se } S(X) \geq \gamma \\ 0, & \text{se } S(X) \leq \gamma \end{cases} \quad (19)$$

Por fim, para obter a probabilidade das ocorrências, é utilizado a simulação Monte Carlo convencional, onde θ pode ser estimada em $f(u)$, através da expressão:

$$\theta = \frac{1}{N} \sum_{i=1}^N I \{S(X) \geq \gamma\} \quad (20)$$

3.6.6 Unidade Linear Retificada (ReLU)

Segundo Nwankpa (2021), a função *Rectified Linear Unit* (ReLU) foi proposta por Nair e Hinton em 2010 e desde então tem sido a função de ativação mais utilizada para aplicações de *Deep Learning*, pois oferece uma alta eficiência se comparado com outras funções, como *Sigmoid* e *Tanh*, sendo reforçado a ideia pelos autores Zeiler (2013) e Dahl (2013).

A função de ativação ReLU é expressa por:

$$f(x) = \max(0, x) = \begin{cases} x_i, & \text{se } x_i \geq 0 \\ 0, & \text{se } x_i \leq 0 \end{cases} \quad (21)$$

Nwankpa (2021) explica que a função retifica valores menores que zero, forçando-os a zero e eliminando o gradiente de desaparecimento, problema observado em outros tipos de função de ativação, ou seja, a principal vantagem de utilizar a função ReLU é que esta não ativa todos os neurônios ao mesmo tempo. Se uma das entradas for negativo, esta entrada será convertida para zero resultando a não ativação do neurônio, tornando a rede mais eficiente e rápida.

3.6.7 Redes Neurais Convolucionais (CNN)

Entre as várias arquiteturas de aprendizagem profunda, as Redes Neurais Convolucionais (CNN) vêm alcançando um notável destaque em suas principais áreas,

tendo grandes avanços no processamento de áudio, vídeo e imagens (LECUN; BENGIO; HINTON, 2015).

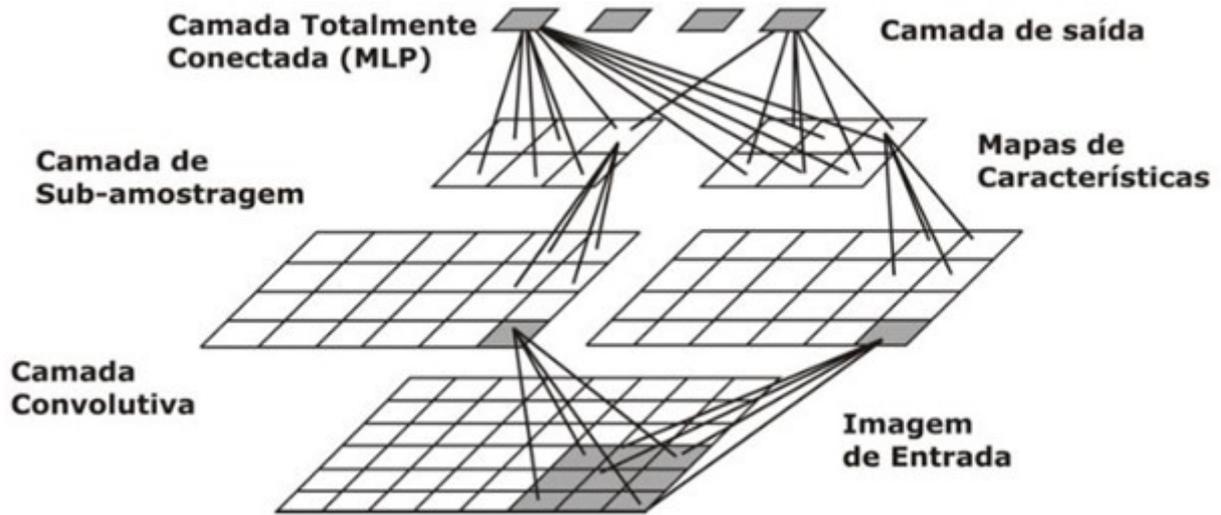
As CNNs foram inspiradas na organização hierárquica do córtex visual e nas noções clássicas de células simples e complexas. De acordo com os experimentos de Hubel e Wiesel (1968), com gatos e macacos, foram observados que células simples foram ativadas quando apresentados padrões simples ao animal, como linhas; e células complexas foram ativadas quando padrões mais elaborados, compostos de combinações de padrões simples, foram apresentados ao animal (HUBEL; WIESEL, 1968; LECUN; BENGIO; HINTON, 2015).

Para Guo *et. al.* (2018), as CNN são redes neurais de multi camadas que utilizam matrizes responsáveis pela filtragem, extraindo características para aprender padrões e detalhes da imagem. Este tipo de rede é muito utilizado para classificação de imagens, embora esta também de forma incomum possa ser aplicada para reconhecimento de sons, como foi feito no trabalho de Jia *et. al.* (2019), o qual copiava a voz de uma pessoa a partir de um áudio de poucos segundos e ao submeter um texto para a rede treinada, a mesma reproduzia a leitura com a voz copiada.

De acordo com Almeida (2019), uma das características mais importantes da CNN é o grande número de arquiteturas que podem ser configuradas, visto que as redes possuem camadas diferentes podendo ser combinadas, incluindo a variação dos parâmetros.

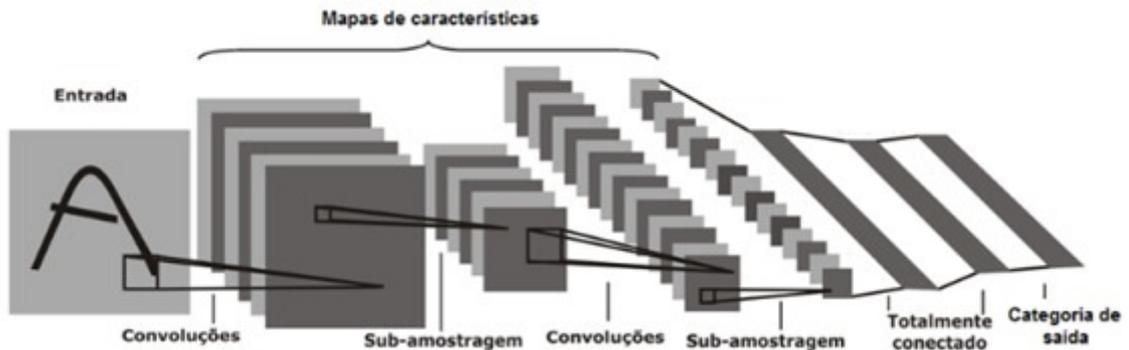
A arquitetura típica de uma Rede Neural Convolutiva é estruturada por uma série de estágios, sendo as primeiras etapas compostas pelas camadas convolucionais e de subamostragem (*subsampling ou pooling*) e as etapas seguintes por camadas totalmente conectadas (Figura 31). As unidades em uma camada convolutiva são 2D organizadas em mapas de características, nos quais, cada unidade é conectada a fragmentos locais nos mapas de características da camada anterior (ou camada de entrada) através de um conjunto de pesos chamados banco de filtros, que são compartilhados entre todas as unidades (LECUN; BENGIO; HINTON, 2015). A Figura 32 apresenta os mapas de características nas camadas convolucionais.

Figura 31: Visão geral da arquitetura de uma Rede Neural Convolutacional



Fonte: Li; Li (1999)

Figura 32: Mapa de característica de uma arquitetura convolutacional



Fonte: Adaptado de Lecun et al (1998)

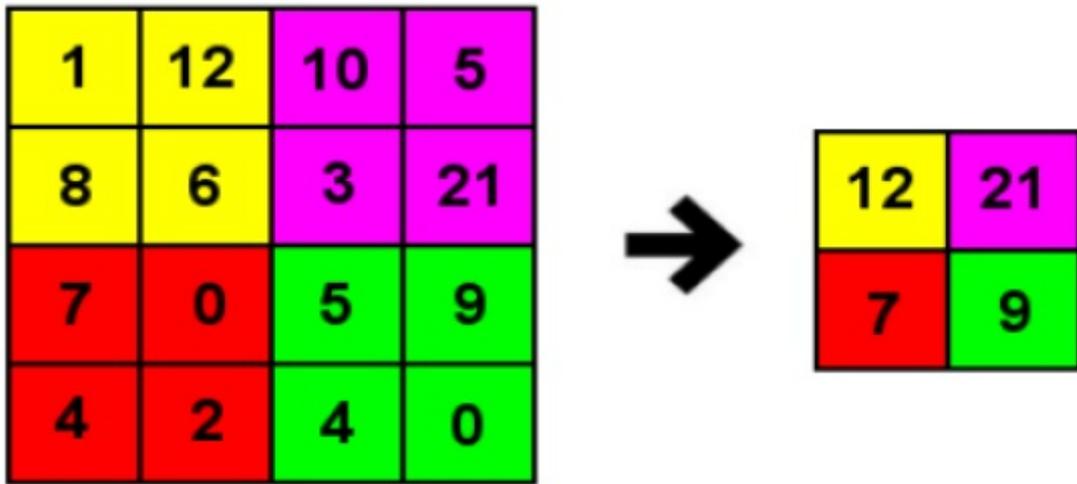
O filtro, também conhecido como kernel, é formado por pesos inicializados aleatoriamente e atualizados a cada nova entrada durante o processo de *backpropagation*. A pequena região da entrada onde o filtro é aplicado é chamada de campo receptivo local (ALVES, 2018). Cada filtro é aplicado em toda região da imagem de entrada de forma convolutacional, resultando no mapa de característica da camada seguinte, ou seja, cada mapa da saída de um estágio corresponde a convolução discreta do filtro com o mapa de características da entrada, daí o nome de Rede Neural Convolutacional. Todas as unidades em um mapa de característica compartilham o mesmo banco de filtros. Mapas diferentes em uma camada usam bancos de filtros diferentes, extraindo assim diferentes tipos de recursos locais (LECUN; BENGIO; HINTON, 2015).

Portanto, a camada convolucional é composta de filtros que são aplicados em toda região da imagem de entrada, onde para cada um destes filtros, um neurônio está conectado a um subconjunto da camada anterior. A operação de filtragem tem a função de detectar bordas, aplicar nitidez e suavização. O resultado da convolução é apresentado a uma função de ativação, que serve para agregar não-linearidade ao sistema e, assim, a rede representar qualquer tipo de função. A função de ativação ReLU (*Rectified Linear Units*) é a mais indicada para Redes Convolucionais por ser mais eficiente computacionalmente e tem o papel de zerar todos os valores negativos da camada anterior (ALVES, 2018; LECUN; BENGIO; HINTON, 2015).

As camadas de pooling têm por função reduzir gradativamente a dimensão das representações da CNN, e com isso, reduzir a resolução do mapa de características e a sensibilidade da saída às mudanças e distorções (LECUN *et al.*, 1998). Dessa forma, diminui-se ainda mais o número de parâmetros e, principalmente, a complexidade computacional do modelo. O papel da camada de pooling é mesclar recursos semanticamente semelhantes, permitindo que as representações variem muito pouco quando os elementos na camada anterior variam em posição e aparência (LECUN; BENGIO; HINTON, 2015). Uma típica camada de *pooling*, chamada de *max-pooling*, computa o máximo local de uma determinada região do mapa de atributos, eliminando valores não máximos, como pode ser visto na Figura 33.

Conseqüentemente, além de reduzir o tamanho da imagem e o processamento para as próximas camadas, essa técnica também auxilia no tratamento de invariâncias locais (FERREIRA, 2017).

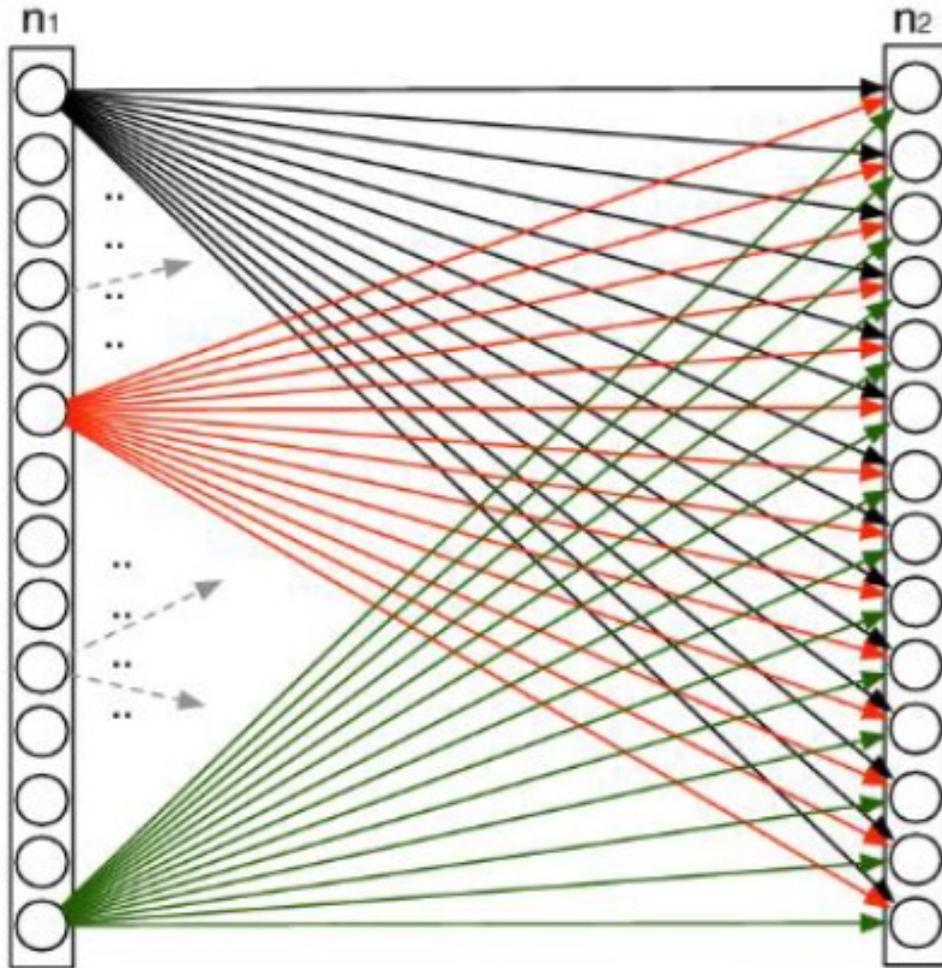
Figura 33: Aplicação de max-pooling 2x2 em uma imagem 4x4



Fonte: Ferreira (2017)

A saída das camadas convolucionais e pooling, em níveis mais altos, representam características da imagem de entrada, e estas são passadas para as camadas totalmente conectadas para a classificação da imagem de acordo com as classes do conjunto de treinamento. As camadas totalmente conectadas possuem conexões com todos os neurônios da camada anterior e, estão conectadas a todos os neurônios da camada seguinte (Figura 34) (KARN, 2016).

Figura 34: Rede neural totalmente conectada



Fonte: Preto (2018)

Em uma Rede Neural Convolutacional é possível ocorrer o problema de *overfitting*, que surge quando a rede é capaz de classificar as imagens de treinamento com exatidão, porém falha ao tentar classificar novas imagens. Na tentativa de reduzir esse efeito, é comum a utilização de técnicas de regularização. Uma das técnicas aplicadas é o *Dropout*, que consiste em remover neurônios aleatoriamente a cada iteração de treinamento, com isso, forçando cada camada da rede a se especializar em uma determinada característica, já que um neurônio não pode depender da presença de outros neurônios (FERREIRA, 2017; FERREIRA; SILVA, 2019; JURASZEK, 2014).

Também com o objetivo de evitar o *overfitting*, pode ser aplicado o método *early stopping* (parada antecipada ou precoce), que tem por função paralisar o treinamento com base no desempenho do conjunto de validação, de forma que, quando não se identifica melhorias no conjunto de validação, o treinamento é interrompido de acordo com os

critérios de parada estabelecidos. Em relação aos critérios, eles podem ser considerados os valores máximo ou mínimo, dependendo da métrica analisada, durante uma determinada quantidade de épocas preestabelecida. O número de épocas sem melhorias após os quais o treinamento é interrompido é denominado como *patience* (GOSWAMI, 2020).

4 METODOLOGIA

Para a identificação das imagens pela CNN, é necessário passar por umas etapas, na qual consiste em coleta de imagens, treinamento da rede neural e avaliação dos resultados e para isso seguirá algumas etapas até o fim do processo. Contudo, antes de detalhar o procedimento, é importante apresentar as ferramentas e a arquitetura da rede.

4.1 Ferramentas

Para o desenvolvimento e treinamento da rede foi utilizado um computador com as seguintes configurações: Intel (R) Core (TM) i5-9300H CPU @ 2.40GHz, 8,00 Gigabyte de memória RAM e placa NVIDIA GTX 1650 com memória de 4 Gigas, com sistema operacional *Windows 10*.

A plataforma na linguagem em python utilizada para o manuseio das bibliotecas, ambientes e configurações básicas de programação foi o Anaconda, devido a sua facilidade de manuseio. Dentro da plataforma foi fornecido um ambiente de desenvolvimento integrado (IDE) em conjunto com a facilidade de instalação das bibliotecas necessárias.

- **Python:** É uma linguagem de programação de alto nível, dinâmica, interpretada, modular, multiplataforma e orientada a objetos. Possui uma sintaxe simples e de fácil compreensão, além de uma grande variedade de bibliotecas. (PYSCIENCE BRASIL, 2022).
- **Spyder:** A IDE possui uma interface bastante intuitiva para manuseio e programação. Possui uma combinação avançada de edição, análise, depuração e criação de perfil. Fácil exploração de dados, inspeção profunda e recursos de visualização. (SPYDER, 2022).
- **TensorFlow:** Plataforma de código aberto que facilita o desenvolvimento e implementação do Aprendizado de Máquinas (Machine Learning) (TENSORFLOW, 2022).

Além da biblioteca TensorFlow/Keras, foram utilizadas as bibliotecas OpenCV, Numpy, Matplotlib, Scikit-learn e Imbalanced-learn.

- **OpenCV**: também conhecido como Open Source Computer Vision, é uma biblioteca aplicada em processamento de imagens para desenvolvimento de aplicativos na área de Visão Computacional (OLIVEIRA, 2019);
- **Numpy**: pacote de processamento de matrizes multidimensionais, que fornece diversas ferramentas para manipulá-las e gerenciá-las (OLIVEIRA, 2019);
- **Matplotlib**: biblioteca de software para criação de gráficos bidimensionais de visualização de dados (OLIVEIRA, 2019);
- **Scikit-learn**: biblioteca de aprendizado de máquina de código aberto que oferece suporte ao aprendizado supervisionado e não supervisionado. Também fornece várias ferramentas para ajuste de modelo, pré-processamento de dados, validação cruzada, seleção e avaliação de modelo, dentre outros vários utilitários;
- **Imbalanced-learn**: biblioteca de código aberto com objetivo de fornecer métodos para lidar com o problema de conjunto de dados desequilibrado, frequentemente encontrado em aplicações de aprendizado de máquina e reconhecimento de padrões. Os métodos são categorizados em, subamostragem, em que as amostras da classe majoritária são descartadas durante o procedimento de balanceamento; sobreamostragem, onde novas amostras são geradas na classe minoritária para atingir uma determinada proporção de balanceamento; e uma combinação entre subamostragem e sobreamostragem para o equilíbrio das amostras (LEMAÎTRE; NOGUEIRA; ARIDAS, 2017).

4.2 Arquitetura da Rede

Neste trabalho foram desenvolvidas duas estruturas de rede, uma para classificação de embarcações e outra para o disco de *plimsoll*. A estrutura da rede é composta de 4 camadas, sendo 3 camadas de neurônios de convolução e 1 camada de neurônio totalmente conectada. A primeira camada é composta de 32 neurônios (filtro) com dimensão 3x3, a segunda possui 64, a terceira possui 128. A primeira camada totalmente conectada possui 512 neurônios que em seguida passa para a segunda camada também totalmente conectada que possui 6 neurônios, os quais são equivalentes a quantidade de resposta para classificação de embarcação, Tabela 1.

Enquanto isso, para a classificação do disco de *Plimsoll*, foi utilizada a mesma estrutura de rede, porém na segunda camada totalmente conectada, foram utilizadas apenas 3 neurônios, Tabela 2. Vale ressaltar que as 3 primeiras camadas da rede possui a função de ativação *Max-pooling* com dimensões 2x2.

Tabela 1: Arquitetura da Rede para classificação de embarcações

Convolação	Nº de Filtros	32
Camada 1	Dim. Filtros	3x3
Max-pooling	Dim. Filtros	2x2
Camada 1		
Convolação	Nº de Filtros	64
Camada 2	Dim. Filtros	3x3
Max-pooling	Dim. Filtros	2x2
Camada 2		
Convolação	Nº de Filtros	128
Camada 3	Dim. Filtros	3x3
Max-pooling	Dim. Filtros	2x2
Camada 3		
Tot. Conectada	Nº de nós	512
Camada 1		
Tot. Conectada	Nº de nós	6
Camada 2		

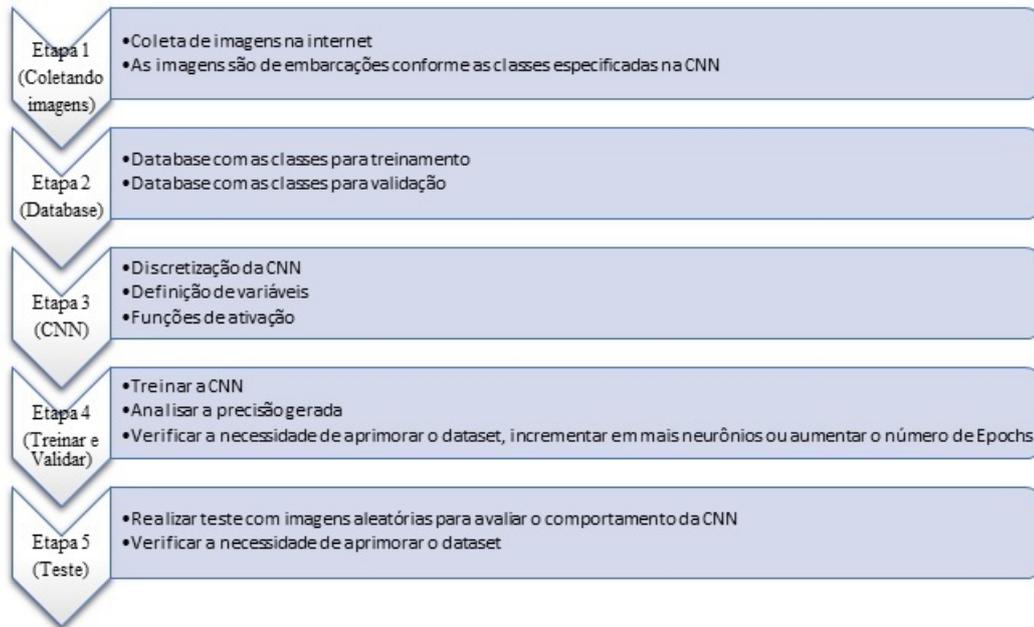
Tabela 2: Arquitetura da Rede para classificação do Disco de Plimsoll

Convolução	Nº de Filtros	32
Camada 1	Dim. Filtros	3x3
Max-pooling	Dim. Filtros	2x2
Camada 1		
Convolução	Nº de Filtros	64
Camada 2	Dim. Filtros	3x3
Max-pooling	Dim. Filtros	2x2
Camada 2		
Convolução	Nº de Filtros	128
Camada 3	Dim. Filtros	3x3
Max-pooling	Dim. Filtros	2x2
Camada 3		
Tot. Conectada	Nº de nós	512
Camada 1		
Tot. Conectada	Nº de nós	3
Camada 2		

4.3 Fluxo do processamento

Será utilizado o seguinte procedimento para a CNN, representado pelo fluxograma 1:

Figura 35: Fluxograma 1 – Etapas do método aplicado a CNN

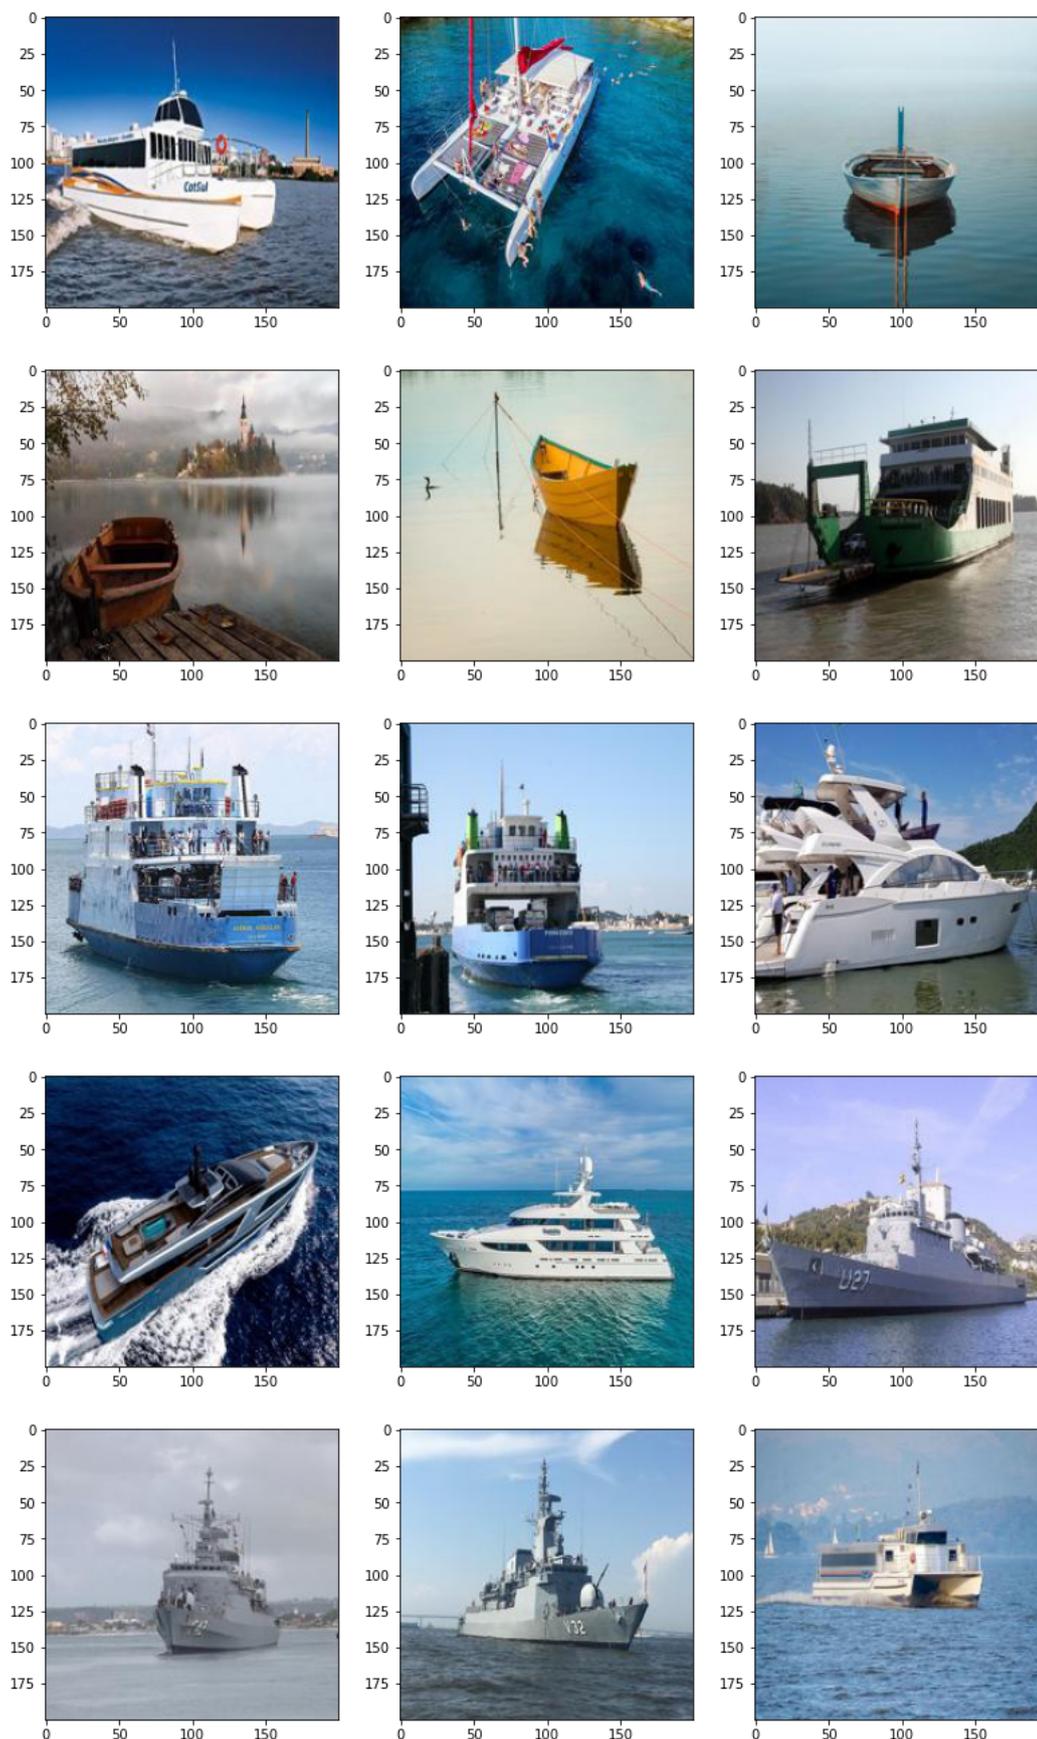


Fonte: Autoria Própria (2021)

Na etapa 1, realizamos a coleta de imagens de várias fontes, todas especificamente das classes determinadas dentro da programação, que são Navio Militar, Ferry Boat, Canoa, Catamarã, Veleiro e Iate, como visto na seção 3.1 e para os Disco de Plimsoll, seção 3.3.

Na etapa 2 criamos um Banco de Dados (Database) contendo inúmeras imagens da internet, das embarcações, Figura 36 e Figura 37, e do disco de plimsoll, Figura 40 e 41.

Figura 36: Exemplo de Imagens utilizadas das embarcações - Banco de dados



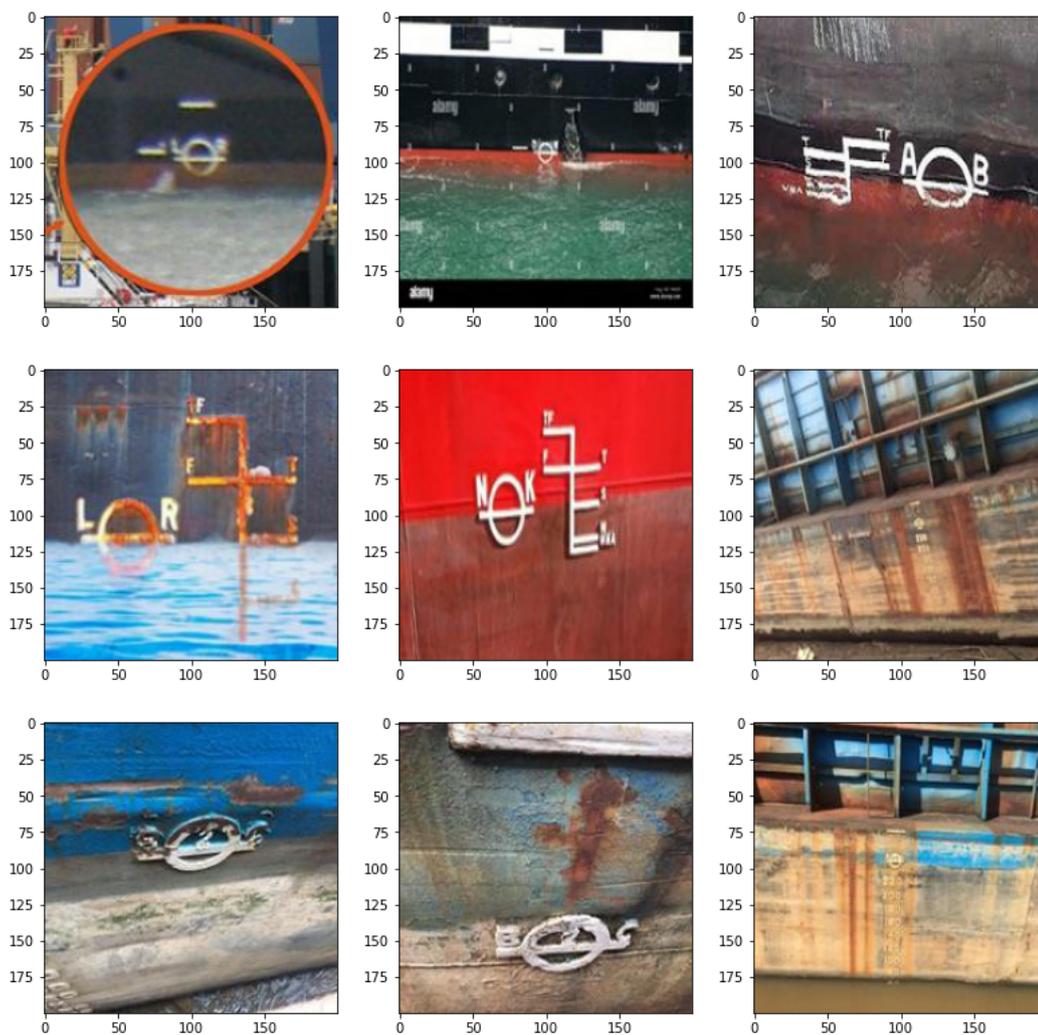
Fonte: Autoria Própria (2021)

Figura 37: Exemplo de Imagens utilizadas das embarcações - Banco de dados



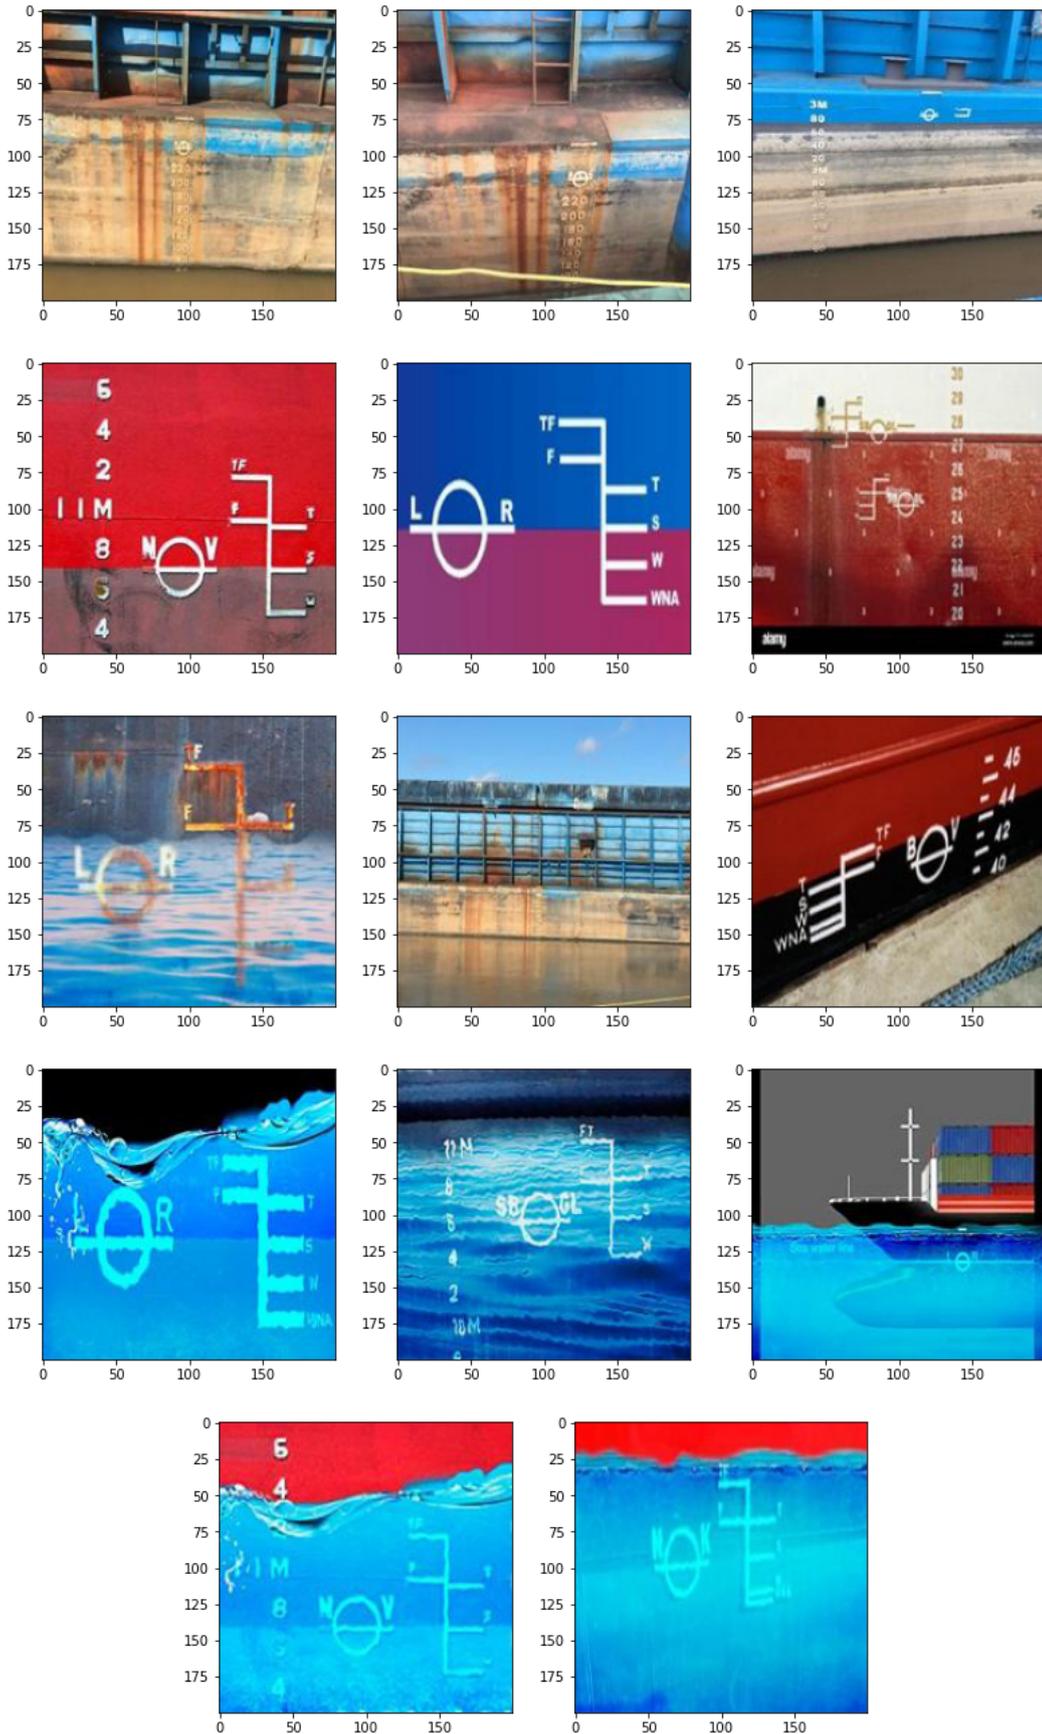
Fonte: Autoria Própria (2021)

Figura 38: Exemplo de Imagens utilizadas dos disco de plimsoll - Banco de dados



Fonte: Autoria Própria (2021)

Figura 39: Fluxograma 1 – Etapas do método aplicado a CNN



Todas as fotografias são diferentes para a realização do treinamento e da validação, pois é importante que o programa possa aprimorar os seus parâmetros com base em vários pontos de perspectiva do tipo da embarcação, sem correr o risco de treinar de forma tendenciosa.

Após a elaboração do *Dataset* de imagens, seguindo para etapa 3, o desenvolvimento do código para classificação de imagens será elaborado na linguagem em *Python*, cuja plataforma é considerada *Open Source* (Recursos Abertos), possibilitando usuários utilizarem de forma gratuita, além de poder usufruir de inúmeras bibliotecas, sendo uma delas o *TensorFlow* (TF), criada pela equipe *Google Brain*.

TF é uma biblioteca de código aberto para *Machine Learning* e a Interface de Programação de Aplicativos (API) que será utilizada para o *Deep Learning* é o *Keras*, o qual possui um conjunto de rotinas de programação (GOOGLE, 2015). Ambas as bibliotecas serão importadas por comandos dentro da plataforma *Python*. Nesta etapa, será discretizado o processo da Rede Neural Convolutiva (CNN), incluindo o número de neurônios, de camadas, funções de ativação, Época (Epoch) e da forma de exibição de resultados em tela.

Após a configuração da CNN e prosseguindo para a etapa 4, a ferramenta será executada, onde irá treinar e validar seus parâmetros para classificação, buscando descartar características sem relevância, por exemplo a presença de água, e priorizar os conteúdos específicos, como forma do casco. Para detalhes sobre sua precisão, será exibido a porcentagem em tela durante todas as épocas do treino.

Por fim a etapa 5, em que consiste em realizar um teste em que é apresentado imagens aleatórias, as quais não constam no *database*, e gerar a previsão dos resultados. Neste caso, se apresentar alguma inconformidade de resultados, este erro pode levar a interpretar que pode estar relacionado as fotografias do banco de dados ou a quantidade de épocas geradas.

Este método será aplicado tanto para a classificação do tipo de embarcação quanto para a análise da borda livre da embarcação.

5 ANÁLISES DOS RESULTADOS

Foram coletadas imagens de seis tipos de embarcações, como visto na seção 3.1, e criado um banco de dados para que a CNN pudesse utilizar para treino. Para o método citado na seção 4, na etapa 3, as configurações quanto a classificação é especificada de forma categórica, pois há mais de duas classes para serem avaliadas.

Como as imagens obtidas possuem dimensões muito grandes, exigindo uma elevada demanda de tempo e de esforço computacional para processar os *pixels*, as mesmas foram redimensionadas para dimensões de 200 *pixels* de comprimento e 200 *pixels* de largura, tamanhos aceitáveis para computadores convencionais.

Determinou-se também que seriam utilizadas 5 camadas de neurônios, a primeira contendo 32 neurônios, a segunda com 64 neurônios, a terceira com 128 neurônios, a quarta com 512 neurônios. As funções de ativação para essas camadas especificadas contêm a função ReLU.

A quinta e última camada é a camada de saída, logo o número de neurônios é igual ao número de entradas. Neste caso, foram utilizadas seis classes que são os tipos de embarcação, tendo a função de ativação a *Softmax*. Para a função de perda (*loss*) utilizou-se a Entropia Cruzada Categórica, a qual colaborou com a avaliação das épocas, para determinar se os resultados estavam convergindo.

Após realizado a configuração, na etapa 4 acontecerá o treinamento da CNN. Durante o treinamento é gerado o valor de precisão (*accuracy*) e de perda (*loss*) para cada época (*Epoch*), conforme Figura 48, tanto para o treinamento e quanto validação.

Figura 40: Valores de precisão (*accuracy*) e perda (*loss*)

```
Epoch 30/30
2/2 [=====] - 2s 1s/step - loss: 0.4745 -
accuracy: 0.7895 - val_loss: 3.3653 - val_accuracy: 0.4231
```

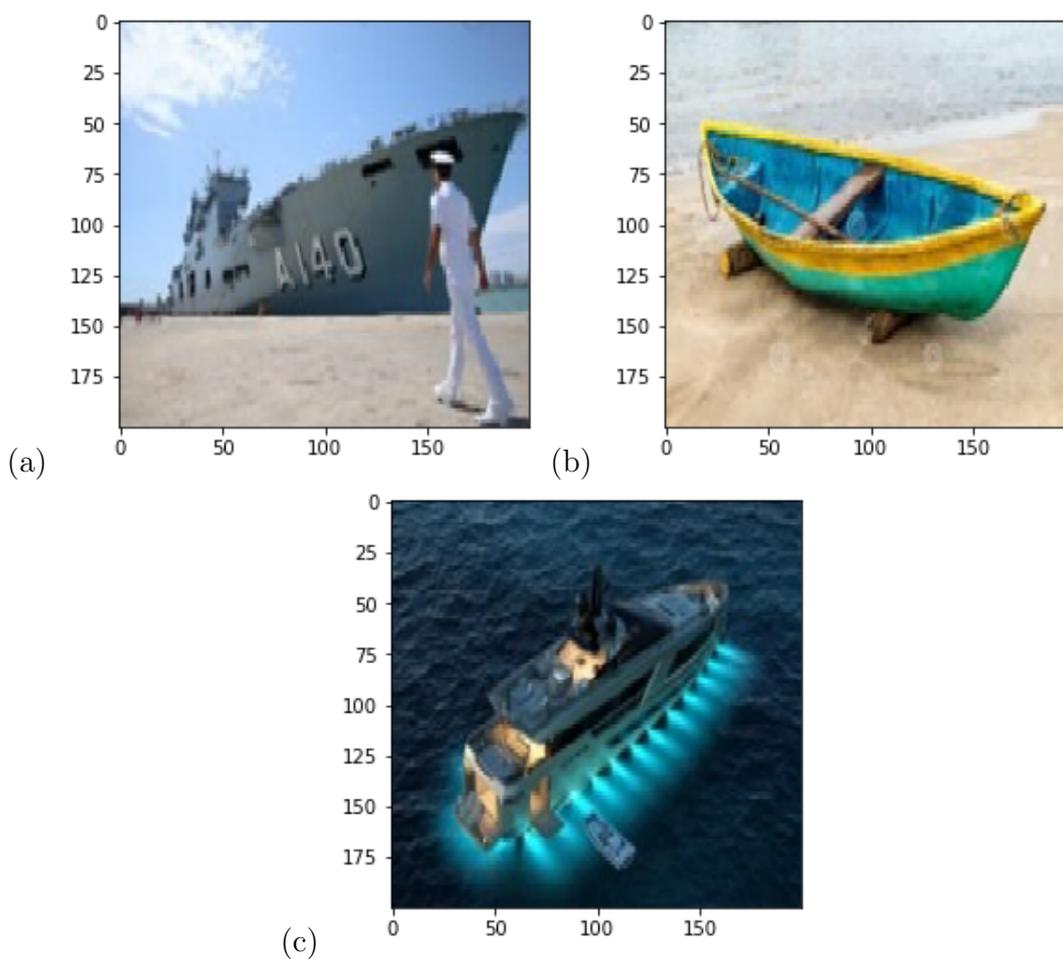
Fonte: Autoria Própria (2021)

Se depois de todas as épocas o valor da precisão não for aceitável, verificar-se-á possibilidade de aumentar a quantidade de imagens para melhorar na distinção, ou se deve incrementar mais camadas de neurônios, ou aumentar o número de épocas. Se após o treino, tudo estiver dentro o esperado, na etapa 5 será fornecido para a CNN imagens

aleatórias de embarcações que não constam no banco de dados para que a mesma possa classificar.

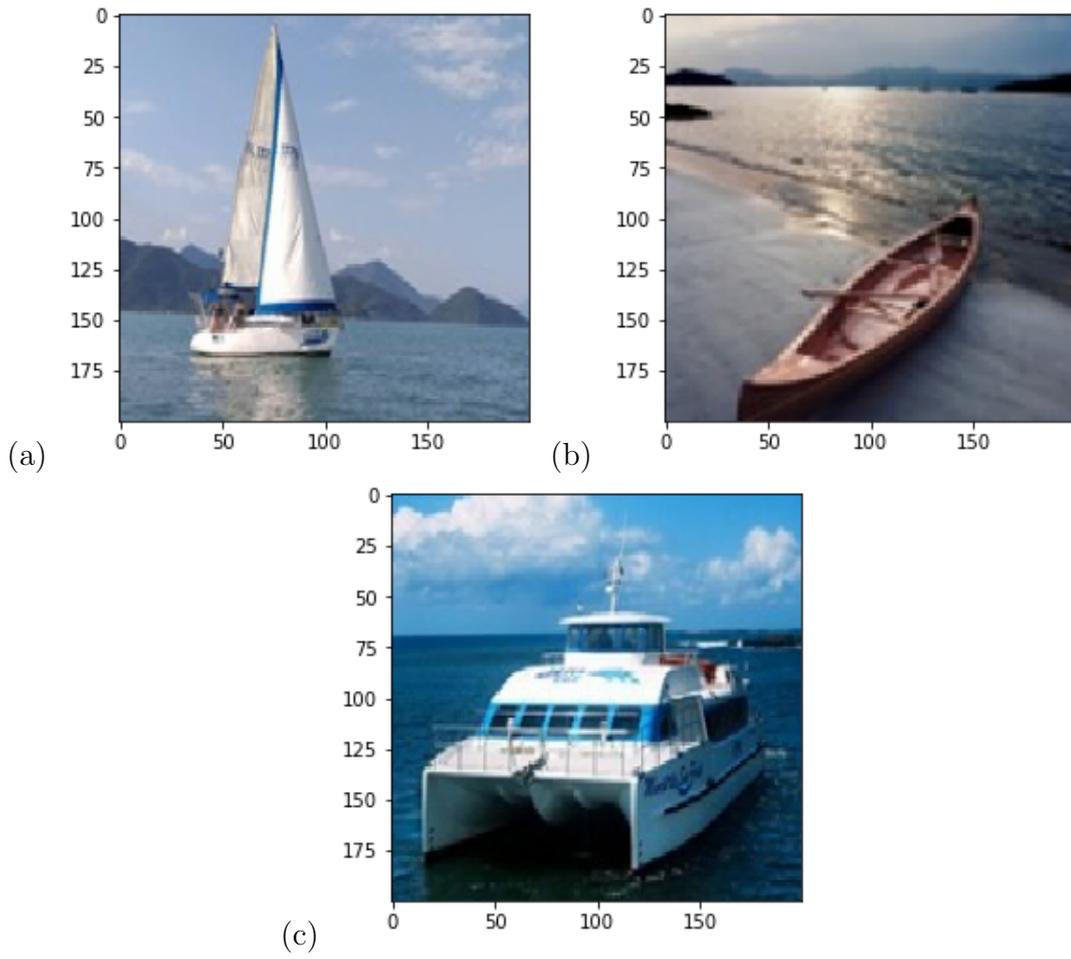
A Rede Neural Convolutacional (CNN) foi programada para classificar imagens quanto ao tipo de embarcação. Nas figuras abaixo foram obtidos resultados para fotografias de embarcações em que a ordem correta das respostas seriam: Navio Militar (Figura 41-a), Canoa (Figura 41-b), Iate (Figura 41-c), Veleiro (Figura 42-a), Canoa (Figura 42-b) e Catamarã (Figura 42-c). Foram realizados testes com 30, 50 e 75 épocas e todos com 2 passos por época, Figuras 43, 44 e 45 respectivamente.

Figura 41: a) Navio Militar, b) Canoa, c) Iate



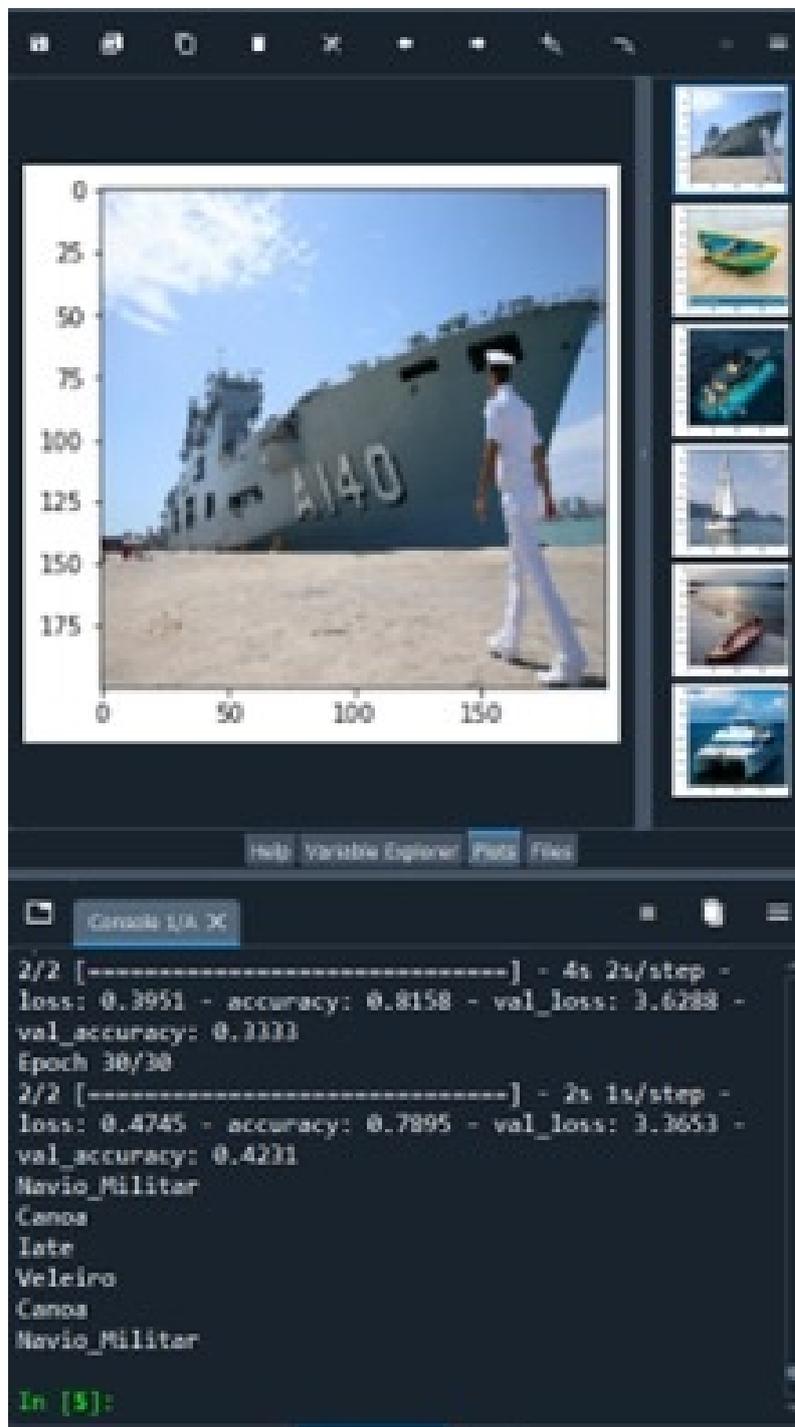
Fonte: Google (2021)

Figura 42: a) Veleiro, b) Canoa, c) Catamarã



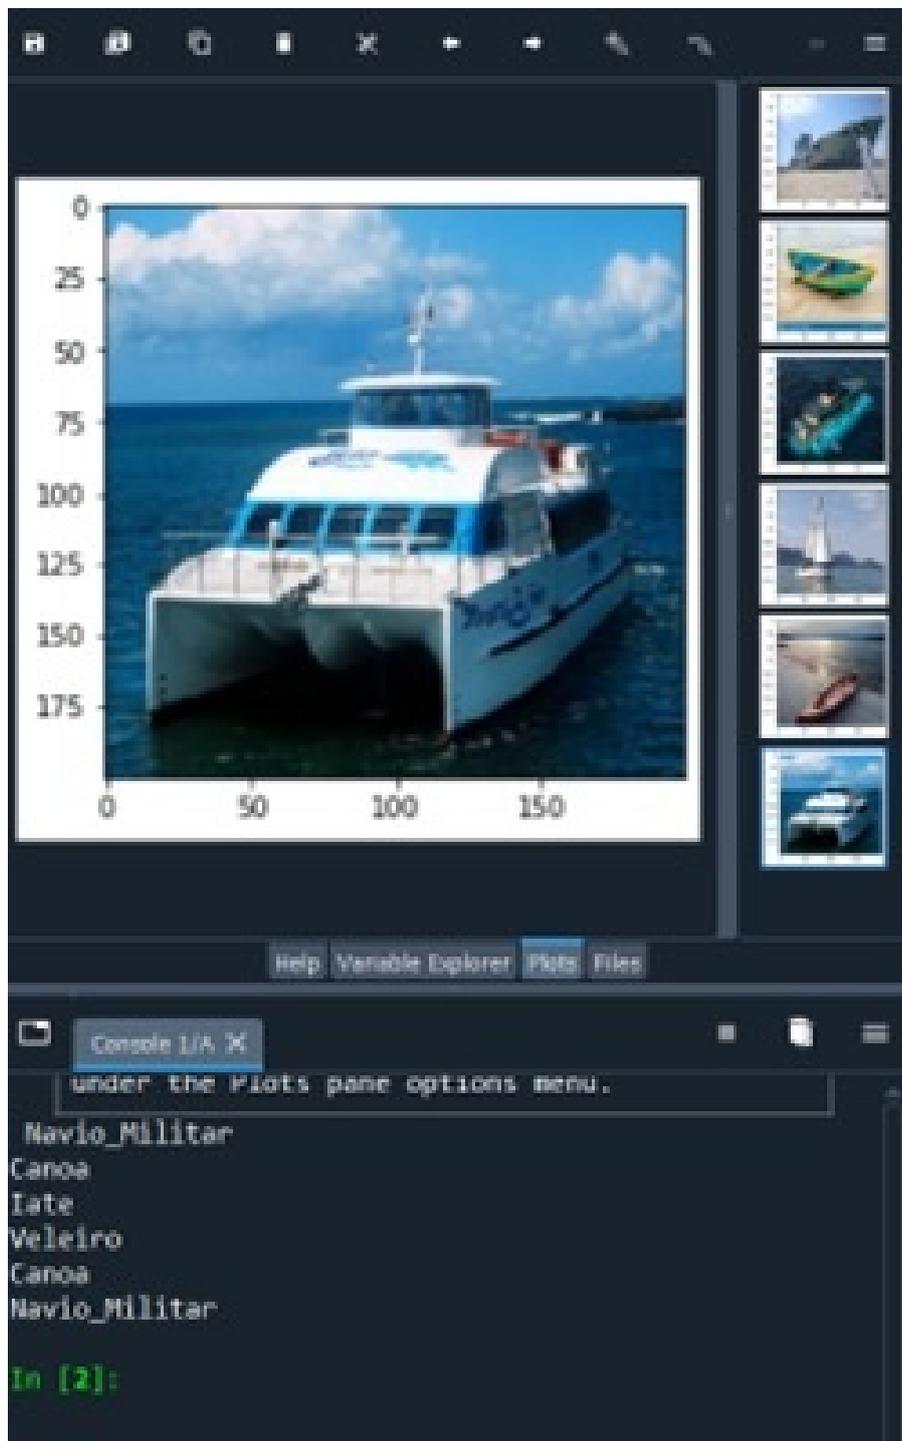
Fonte: Google (2021)

Figura 43: Resultado da previsão do resultado para treinamento de 30 épocas



Fonte: Autoria Própria (2021)

Figura 44: Resultado da previsão do resultado para treinamento de 50 épocas



Fonte: Autoria Própria (2021)

Figura 45: Resultado da previsão do resultado para treinamento de 75 épocas

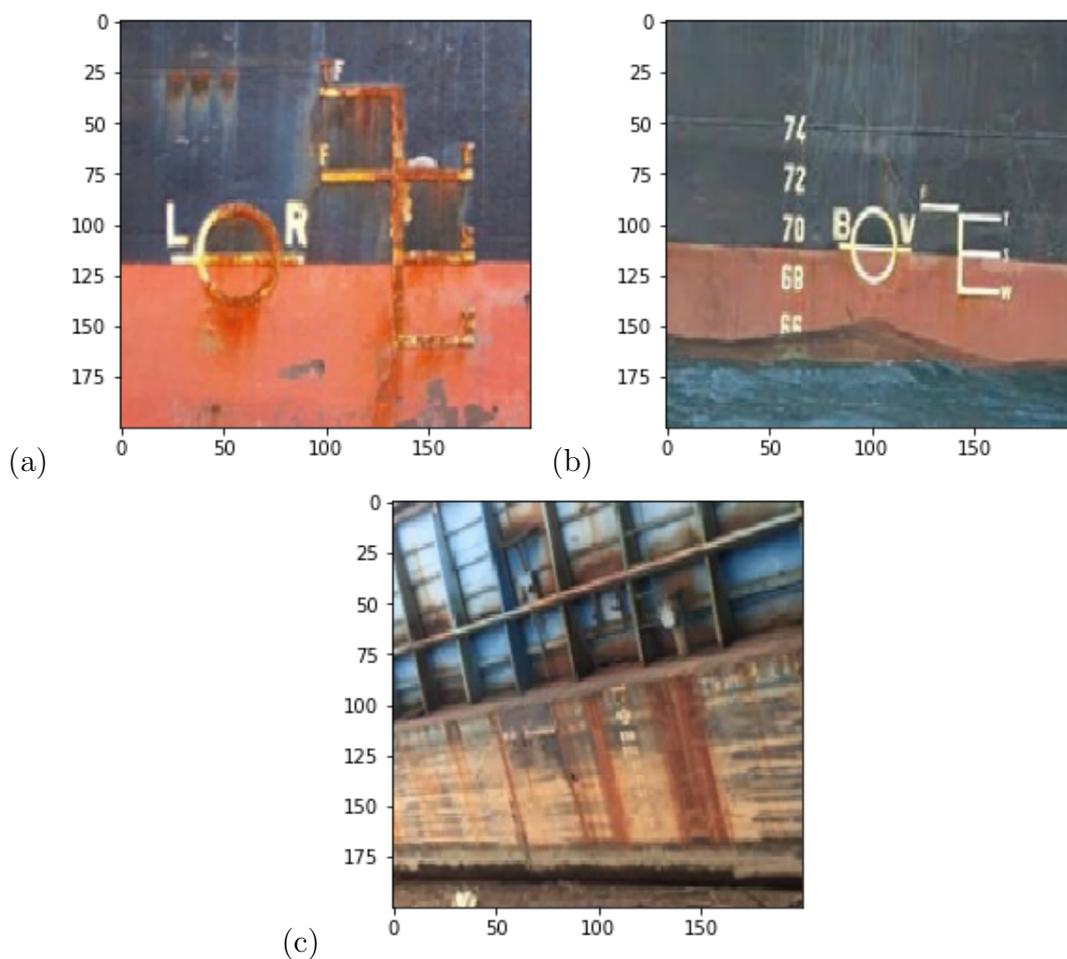


Fonte: Autoria Própria (2021)

Pode-se observar que houve erro na última classificação para treinos de 30 e 50 épocas. Porém, para 75 épocas a rede apresentou acerto em todas as suas classificações.

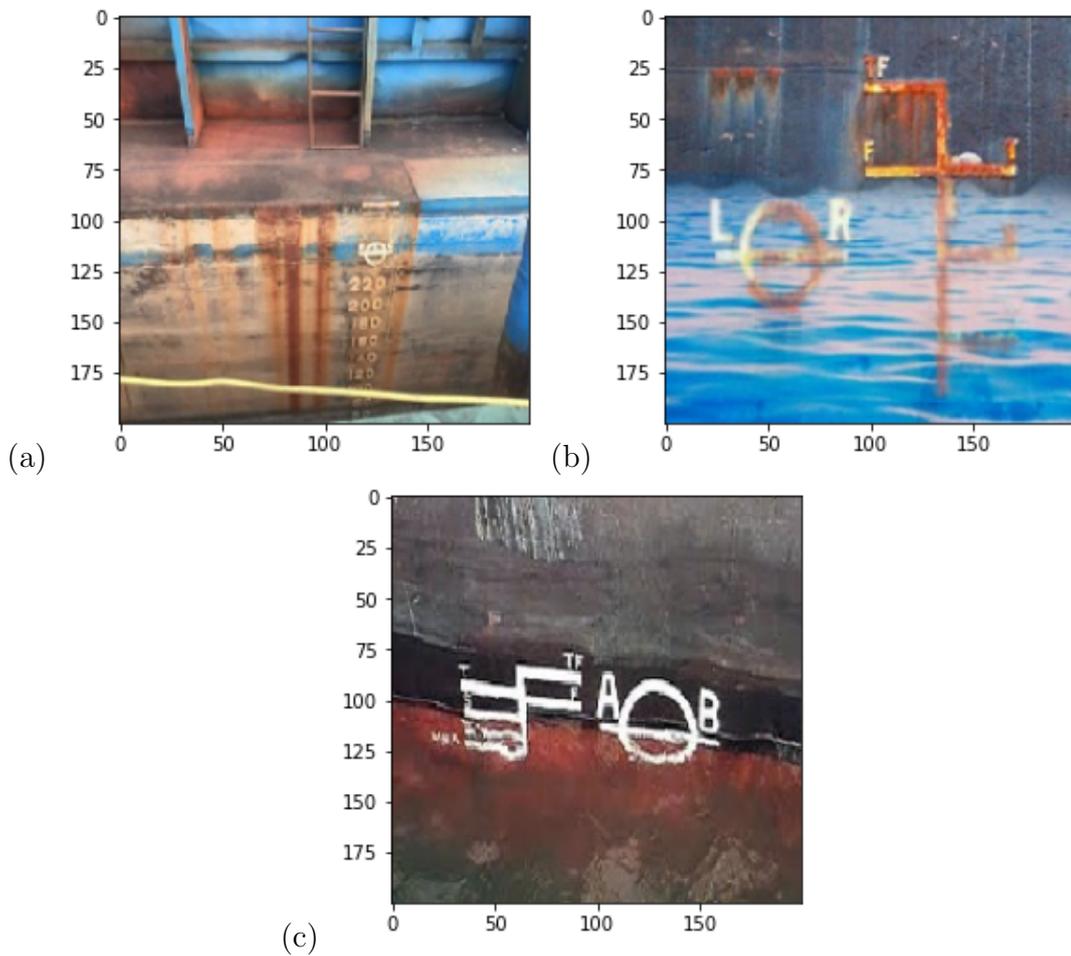
Para o Disco de Plimsoll foram consideradas 3 tipos de carregamento: leve, carregado e sobrecarregado, conforme especificado na seção 2.3. A quantidade de neurônios se manteve o mesmo, porém o número de épocas passou a ser 20 e o passos por época 5. Foram considerados dois casos, o primeiro em que fossem fornecidas 6 imagens aleatórias do disco de plimsoll, para que a rede neural analisasse, vide Figuras 46 e 47.

Figura 46: a) Leve; b) Leve; c) Leve



Fonte: Google (2021)

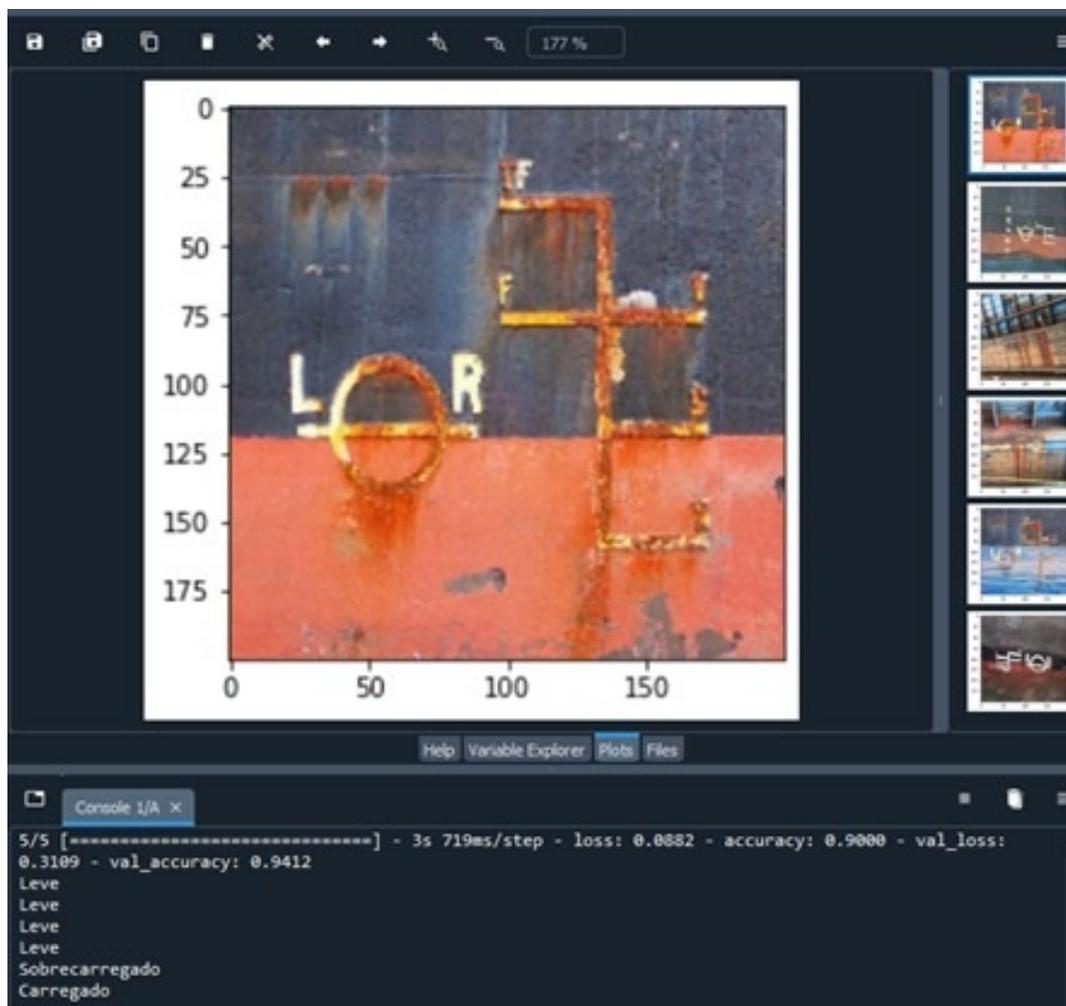
Figura 47: a) Leve; b) Sobrecarregada; c) Carregada



Fonte: Google (2021)

As Figuras 46 e 47 apresentam a ordem de imagens que foi fornecido para a rede neural, a qual a resposta certa é: Leve, Leve, Leve, Leve, Sobrecarregada e Carregada. Após o fornecimento das imagens para a rede analisar, foram gerados os seguintes resultados, Figura 48.

Figura 48: Resultado da previsão do resultado para treinamento de 20 épocas com 5 passos por época

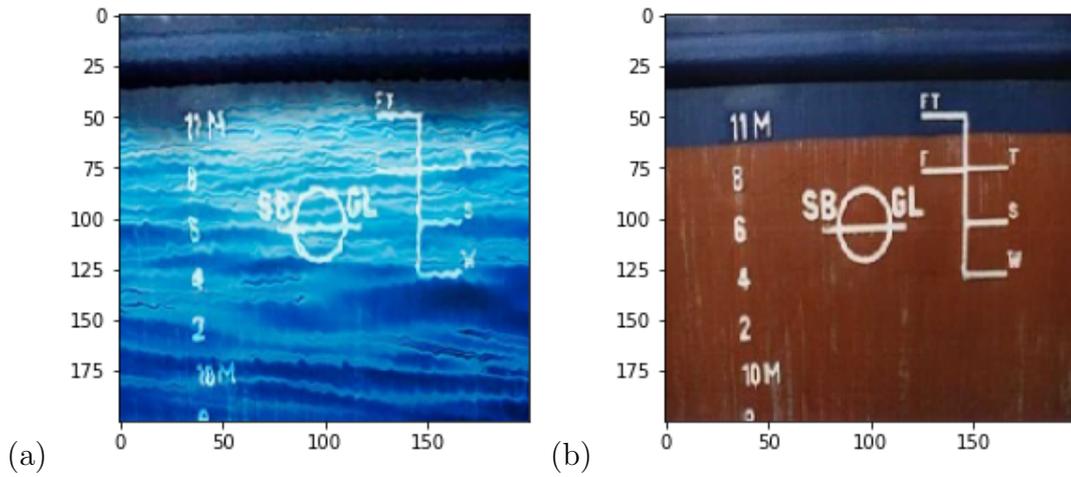


Fonte: Autoria Própria (2021)

A rede neural respondeu de forma correta em relação as imagens fornecidas, o que pode-se observar que atingiu resultados satisfatórios com relação as previsões em diferentes tipos de imagens e condições.

Em seguida, aproveitando a rede, foi simulado um caso de uma embarcação específica, duas imagens representando os bordos de uma mesma embarcação, porém um com a imagem real e a outra foi utilizado a mesma imagem, porém modificado para que pudesse simular uma situação real, no caso ter imagens dos bordos de uma mesma embarcação. Nesta embarcação o bordo está sobrecarregado, Figura 49a, e o outro bordo está com condição leve, figura 49b, o que representa uma embarcação em condição de banda

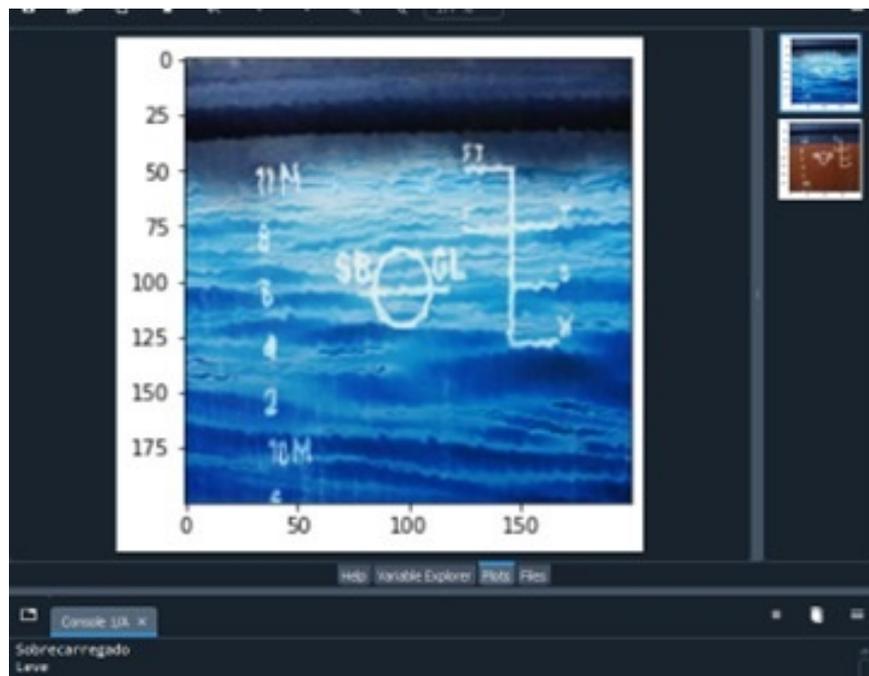
Figura 49: a) Sobrecarregada; b) Leve



Fonte: Google (2021)

Após a submissão das imagens na rede neural, a mesma gerou os seguintes resultados, Figura 52. Pode-se observar que em uma condição real, em que é fornecido imagens que pertencem os bordos de uma mesma embarcação, a rede neural apresentou acerto nas suas previsões, que eram: Sobrecarregada e Leve.

Figura 50: Simulação do disco de plimsoll de uma mesma embarcação



Fonte: Autoria Própria (2021)

6 CONCLUSÕES

Com o desenvolvimento desta ferramenta foi possível atribuir uma metodologia utilizando uma das áreas Inteligência Artificial que é o *Deep Learning*. Através disso foi possível criar uma rede neural convolucional que pudesse classificar quanto ao tipo de embarcação e o carregamento da embarcação através do disco de *plimsoll*.

A inteligência artificial tem sido cada vez mais utilizada em todos os setores do mercado. Neste caso, ela pode ser aprimorada cada vez mais para ser utilizada na garantia da segurança da navegação, o que pode impactar futuramente em uma redução de acidentes. Não só através de análise de imagens como também pode ser expandida e utilizada de outras maneiras.

Pode-se observar também que a Rede Neural Convolucional apresentou resultados satisfatórios, apesar do banco de dados não ser vasto, o qual normalmente em média atinge milhares de imagens, porém conseguiu servir para que a rede treinasse e aprendesse a classificar os tipos de embarcações em diferentes situações e o disco de *plimsoll* em 3 tipos de carregamento: Leve, Carregada e Sobrecarregada.

Foi coletado imagens da internet e da região para a elaboração do banco de dados, apesar da dificuldade em arranjar dados do disco de *plimsoll*, devido ao acesso as embarcações e a condição de sobrecarga que não é comum de ser observado, pode-se contornar através do uso de dados sintéticos.

Para trabalhos futuros, é possível desenvolver novas redes ou aprimorar a CNN deste trabalho para ser analisado imagens em tempo real, análise de estrutura, busca de documentos da embarcação, incrementar o banco de dados para classificar mais tipos de embarcações, utilização de redes neurais na parte da segurança portuária, observando embarcações que atracam. A utilização da rede neural é bem vasta.

Referências

- [1] ALMEIDA, C. C. **Identificação e Classificação de Imagens usando Rede Neural Convolucional e Machine Learning: Implementação em Sistema Embarcado**. Tese (Doutorado em Engenharia Mecânica), Universidade Estadual de Campinas, Campinas, 2019.

- [2] ALMEIDA, Luiz Eduardo Pita Mercês. **Estudo de caso em Reconhecimento Automático de Placas Veiculares usando linguagem de programação Python**. Orientador: Dr. José Maurício Ramos de Souza Neto. 2018. 89 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Universidade Federal da Paraíba, João Pessoa, 2018.
- [3] ALVES, Gisely. **Entendendo Redes Convolucionais (CNNs)**. Neuronio BR, 2018.
- [4] ANJOS, J. R. L. **InferenCNN: Uma biblioteca para Inferência de Redes Neurais Convolucionais Multiplataforma em OpenCL**. Dissertação (Mestrado em Ciência da Computação). Universidade Federal de Pernambuco, Pernambuco, 2019.
- [5] ANTÓNIO, C. T. M. **Classificação de Navios Baseados em Assinaturas Acústicas**. Dissertação (Mestrado em Ciências Militares Navais) – Escola Naval. Alfeite, 2019.
- [6] BENGIO, Y. et al. **Learning Deep Architectures for AI. Foundations and trends in Machine Learning**, Now Publisher, Inc., v. 2, n. 1, p. 1- 127, 2009.
- [7] BISHOP, C. M. **Pattern recognition and machine learning**. Springer, 2006.
- [8] BRASIL. **Decreto nº 2.153, de 20 de fevereiro de 1997. Estabelece e organiza as Forças Navais, Aeronavais e de Fuzileiros Navais da Marinha, dispõe sobre as áreas de jurisdição dos Comandos de Distritos Navais e dá outras providências**. Diário Oficial da União, Brasília.
- [9] CABRAL, J. P. F. S. **Arquitetura Naval: Estabilidade, Cálculos, Avaria e Bordo Livre**. Rio de Janeiro: Centro do Livro Brasileiro, 1979.
- [10] CLOVER, F.; TAILARD, E.; WERRA, D. **A Users Guide to Tabu Search, Annals of Operations Research**, Vol. 41, 1993.
- [11] CONFEDERAÇÃO NACIONAL DO TRANSPORTE – CNT. **Aspectos Gerais da Navegação Interior no Brasil**. Brasília, 2019. Disponível em: < [https : //cnt.org.br/painel – hidroviario](https://cnt.org.br/painel-hidroviario) >. Acesso em: 07 de jul. de 2021.

- [12] DALAL, Navneet; TRIGGS, Bill. **Histograms of oriented gradients for human detection**, 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, França, V. 1, p. 886–893, 2005.
- [13] DAHL, G. E.; SAINATH, T. N.; HINTON, G. E. **Improving deep neural networks for LVCSR using rectified linear units and dropout** in International Conference on Acoustics, Speech and Signal Processing. IEEE, 2013.
- [14] DOKKUN, K. V. **Ship Knowledge**. 8th edition. Enkhuizen: Dokmar Maritime Publishers B.V., 2013a.
- [15] DOKKUN, K. V. et al. **Ship Stability**. 5th edition. Enkhuizen: Dokmar Maritime Publishers B.V., 2013b.
- [16] FAGHIH-ROOHI, Shahrzad et al. **Deep convolutional neural networks for detection of rail surface defects**. Proceedings of the International Joint Conference on Neural Networks, [S.l.], p. 2584–2589, jul. 2016.
- [17] FAUSETT, L. **Fundamentals of Neural Networks: Architectures, Algorithms, and Applications**. Prentice-Hall, 1994. (Prentice-Hall International editions).
- [18] FERREIRA, Alessandro dos Santos. **Redes Neurais Convolucionais Profundas na Detecção de Plantas Daninhas em Lavoura de Soja**. 2017. 70 f. Dissertação (Mestrado em Ciências da Computação) - Universidade Federal de Mato Grosso do Sul - Faculdade de Computação - FACOM, Mato Grosso do Sul, 2017.
- [19] FURTADO, M. I. V. **Redes Neurais Artificiais: Uma abordagem para sala de aula**. Ponta Grossa: Atena, 2019
- [20] GIBERT, Xavier; PATEL, Vishal M.; CHELLAPPA, Rama. **Material classification and semantic segmentation of railway track images with deep convolutional neural networks**. IEEE International Conference on Image Processing (ICIP), [S.l.], p.621–625, set. 2015.
- [21] GOOGLE. **An open source machine learning library for research and production**. 2015. TensorFlow.

- [22] GOOGLE. **Object Detection**. 2017. Disponível em:
- [23] GOSWAMI, Saptarsi. **Introduction to Early Stopping: an effective tool to regularize neural nets**. Towards Data Science, 2020.
- [24] GUO, K. et al. **Angel-eye: A complete design flow for mapping cnn onto embedded fpga**. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, IEEE, v. 37, n. 1, p. 35–47, 2018.
- [25] HUBEL, D. H.; WIESEL, T. N. **Receptive fields and functional architecture of monkey striate cortex**. The Journal of Physiology, v. 195, n. 1, p. 215–243, 1 mar. 1968.
- [26] JANUÁRIO, Jailson; GUEDES, Elloá; SILVA, Fabio. **Classificação do Índice Glicêmico a partir de Imagens de Alimentos com Redes Neurais Convolucionais**. Sociedade Brasileira de Computacao - SB, Manaus, p. 493–502, 2018.
- [27] JURASZEK, Guilherme Defreitas. **Reconhecimento de produtos por imagem utilizando palavras visuais e redes neurais convolucionais**. Orientador: Alexandre Gonçalves Silva. 2014. 155 f. Dissertação (Mestrado em Computação Aplicada) - Universidade do Estado de Santa Catarina, Santa Catarina, 2014.
- [28] JIA, Y. et. al. **Transfer Learning from Speaker Verification to Multispeaker Text-to-Speech Synthesis**. In: 32nd Conference on Neural Information Processing Systems (NeurIPS), Montréal, 2018.
- [29] KARN, Ujjwal. **The data science blog: An intuitive explanation of convolutional neural networks**. Wordpress, 2016.
- [30] LACERDA, K. B. **Proposta de Prevenção de acidentes em embarcações de transporte de passageiros**. Dissertação (Mestrado em Engenharia de Transportes), Instituto Militar de Engenharia, Rio de Janeiro, 2015.
- [31] LECUN, Y.; BENGIO, Y; HINTON, G. **Deep Learning**. Nature, Nature Publishing Group, v. 521, n 7553, p. 436, 2015.

- [32] LOBO, V.J.A.S. **Application of Self-Organizing Maps to the Maritime Environment**. In: Popovich V.V., Claramunt C., Schrenk M., Korolenko K.V. (eds) Information Fusion and Geographic Information Systems. Lecture Notes in Geoinformation and Cartography. Springer, Berlin, Heidelberg, 2009.
- [33] LUCENA, L. **Noções de Estabilidade de Embarcações Náuticas**. BlogSpot, 21 de janeiro de 2018.
- [34] MARINHA DO BRASIL – **Diretoria de Portos e Costas “Normas da Autoridade Marítima para Embarcações Empregadas na Navegação Interior – Normam – 02”**, 2005.
- [35] MARINHA DO BRASIL – **Diretoria de Portos e Costas “Normas da Autoridade Marítima para Reconhecimento de Sociedades Classificadoras e Certificadoras (Entidades Especializadas) para atuarem em nome do Governo Brasileiro – Normam – 06”**, 2017.
- [36] MARINHA DO BRASIL – **Diretoria de Portos e Costas “Inquéritos Administrativos sobre Acidentes e Fatos da Navegação - IAFN”**, 2020.
- [37] MARINHA DO BRASIL – **Diretoria de Portos e Costas “Inquéritos Administrativos sobre Acidentes e Fatos da Navegação - IAFN”**, 2021.
- [38] MENEZES, C. **Reconhecimento de Imagens por Redes Neurais Convolucionais (CNN) em Sistemas Embarcados**. 2018.
- [39] MICROSOFT. **Text Analytics**. 2018.
- [40] MOREIRA, C. Neurónio. **Revista de Ciência Elementar**. Porto, Vol. 1, n° 1, 1(01):0006, Outubro de 2013.
- [41] MOREIRA, E. S. Coleção Monografias **Neuroanatômicas Morfo-Funcionais: Os Neurônios, as Sinapses, O Impulso Nervoso e os Mecanismos Morfo-Funcionais de transmissão dos sinais neurais no Sistema Nervoso**. Vol. 2. Volta Redonda. Centro Universitário de Volta Redonda, 2017.

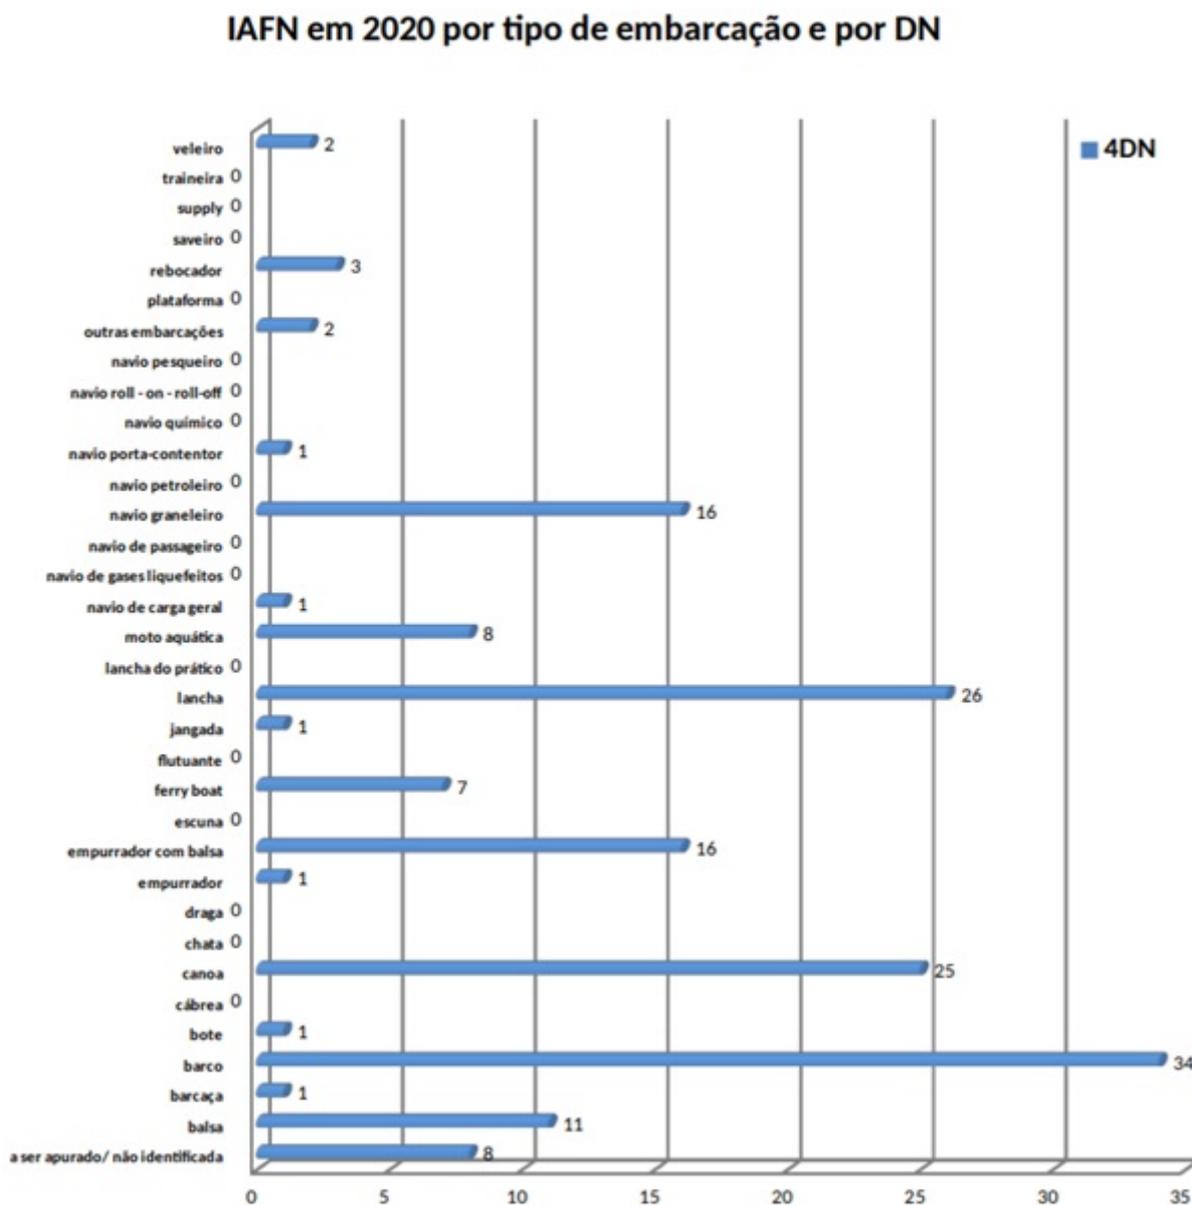
- [42] NAIR V.; HILTON G. E. **Rectified Linear Units Improve Restricted Boltzmann Machines**. Department of Computer Science, University of Toronto, Toronto, ON M5S 2G4, Canada. 2010
- [43] NWANKPA, C. E. et al. **Activation Functions: Comparison of Trends in Practice and Research for Deep Learning**. In: 2nd International Conference on Computational Sciences and Technology, pág. 124-133, Jamshoro, 2021.
- [44] OLIVEIRA, F. B. R. **Redução de Perdas de Sistemas de Distribuição através do Dimensionamento Ótimo de Bancos de Capacitores via Entropia Cruzada**. Dissertação (Mestrado em Engenharia Elétrica), Universidade de São Paulo, São Paulo, 2016.
- [45] PRETO, Daniela de Oliveria. **Reconhecimento de placas de trânsito por meu de deep learning**. Orientador: Dr. Mauro Roisenberg. 2018. 85 f. Trabalho de Conclusão de Curso (Graduação em Ciências da Computação) - Universidade Federal de Santa Catarina - Departamento de Informática e Estatística, Florianópolis, 2018.
- [46] PYSCIENCE BRASIL. **Python: O que é? Por que usar?**. Pyscience-Brasil, 2022. Disponível em: <http://pyscience-brasil.wikidot.com/python:python-oq-e-pqj>. Acesso em: 02 out 2022.
- [47] ROCHA, P. L. **Reconhecimento de Voz utilizando Seleção Dinâmica de Redes Neurais**. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal do Maranhão, Maranhão, 2018.
- [48] RONNEBERGER et. al. **Medical Image Computing and Computer-Assisted Intervention**. International Conference on Medical Image Computing and Computer-Assisted Intervention. pp 234–241. 2015
- [49] Rosenblatt, F. **The perceptron: A probabilistic model for information storage and organization in the brain**. Psychological Review, 65(6), 386–408, 1958
- [50] Rubinstein R. Y **Optimization of computer simulation models with rare event**. European Journal of Operational Research Volume 99, Issue 1, 16 May 1997, Pages 89-112

- [51] SCOTT D. W. **Multivariate Density Estimation: Theory, Practice, and Visualization** 2015.
- [52] SHANG, Lidan et al. **Detection of rail surface defects based on CNN image recognition and classification**. International Conference on Advanced Communication Technology, Shenyang, p. 45–51, fev. 2018.
- [53] SIEGEL, J. E. et al. **Real-time deep neural networks for internet-enabled arc-fault detection**. Engineering Applications of Artificial Intelligence, Elsevier, v. 74, 2018.
- [54] SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, 2019.
- [55] SPYDER. **The Scientific Python Development Environment**. Spyder.
- [56] TENSORFLOW. **Por que usar TensorFlow**. Tensorflow.
- [57] TRINDADE, Lucas Lopes. **Detecção de obstáculos para carros autônomos utilizando aprendizado profundo**. Orientador: Dr. Hector Pettenghi Roldan. 2018, 85 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Universidade Federal de Santa Catarina, Florianópolis, 2018.
- [58] TURING, A. M. **COMPUTING MACHINERY AND INTELLIGENCE**. Oxford Journals. Mind 59, n. 236, pág. 433-460, Inglaterra, 1950.
- [59] VARGAS, Ana Caroline Gomes; PAES, Aline; VASCONCELOS, Cristina Nader. **Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres**. Proceedings of the XXIX Conference on Graphics, Patterns and Images, p. 1–4, 2016.
- [60] VASCONCELLOS, Paulo. **Como saber se seu modelo de Machine Learning está funcionando mesmo**. Medium, 2018.
- [61] VOGADO, Luis H. S. et al. **Rede Neural Convolucional para o Diagnóstico de Leucemia**. Sociedade Brasileira de Computacao - SB, p. 46–578, ago. 2019.

- [62] YANAI, F. K. **Detecção de anomalias no funcionamento de software com Machine Learning**. Dissertação (Mestrado em Tecnologias da Inteligência e Design Digital), Universidade Católica de São Paulo, São Paulo, 2020.
- [63] ZEILER, M. D.; Ranzato, M.; Monga, R.; Mao, M.; Yang, K.; Le, Q. V. e Hinton, G. E. **On rectified linear units for speech processing**. Em International Conference on Acoustics, Speech and Signal Processing. IEEE, 2013, pp. 3517-3521, IEEE. <https://doi.org/10.1109/ICASSP.2013.6638312>.
- [64] ZUBALY, R. B. **Applied Naval Architecture**. Atglen: Schiffer Publishing Ltd., 2011.

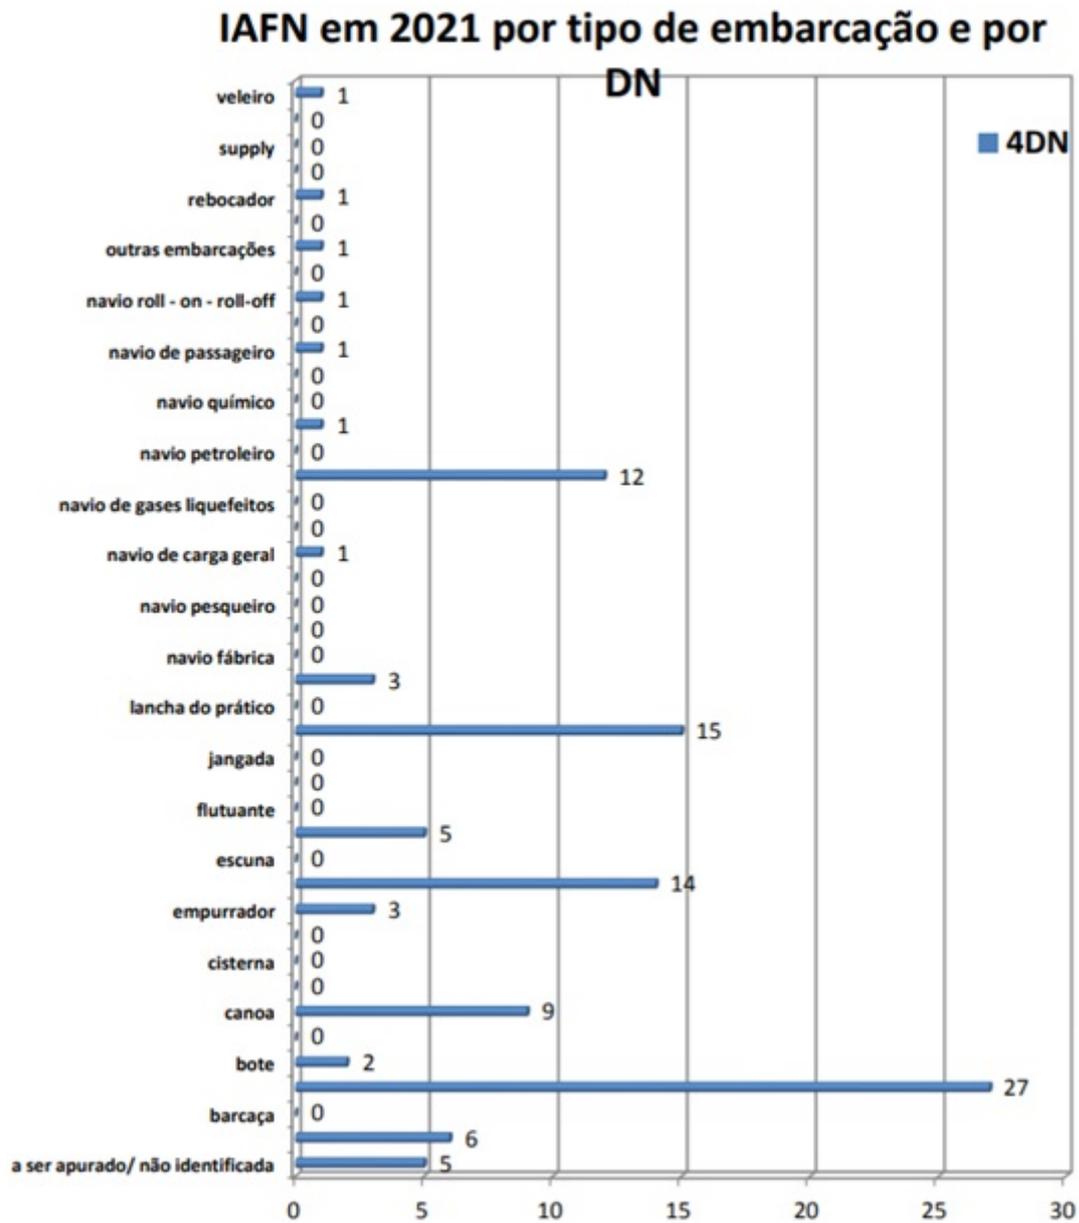
ANEXOS

Figura 51: Acidentes por tipo de embarcação de 2020



Fonte: Autoria Própria (2021)

Figura 52: acidentes por tipo de embarcação de 2021



Fonte: Autoria Própria (2021)