



## APLICAÇÃO DE APRENDIZAGEM DE MÁQUINA NO ALINHAMENTO DE EIXO PROPULSOR DE NAVIOS

Diego Landim Magalhães

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Oceânica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Oceânica.

Orientador: Luiz Antônio Vaz Pinto

Rio de Janeiro

Abril de 2023

APLICAÇÃO DE APRENDIZAGEM DE MÁQUINA NO ALINHAMENTO DE EIXO  
PROPULSOR DE NAVIOS

Diego Landim Magalhães

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ  
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA  
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS  
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM  
ENGENHARIA OCEÂNICA.

Orientador: Luiz Antônio Vaz Pinto

Aprovada por:

---

Prof. Luiz Antônio Vaz Pinto, D.Sc.

---

Prof. Ulisses Admar Barbosa Vicente Monteiro, D.Sc.

---

Prof. Ricardo Homero Ramírez Gutierrez, D.Sc.

---

Eng. Dionísio Henrique Carvalho de Sá Só Martins, D.Sc.

---

Prof. Antonio Carlos Ramos Troyman, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

ABRIL DE 2023

Magalhães, Diego Landim

Aplicação de Aprendizagem de Máquina no Alinhamento de Eixo Propulsor de Navios / Diego Landim Magalhães – Rio de Janeiro: UFRJ/COPPE, 2023.

XIV, 80 p.: il.; 29,7 cm.

Orientador: Luiz Antônio Vaz Pinto.

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Oceânica, 2023.

Referências Bibliográficas: p. 69-72.

1. Aprendizagem de Máquina. 2. Alinhamento de Eixos Principais. 3. Sistema Propulsivo. 4. Problemas de classificação multiclasse. I. Pinto, Luiz Antônio Vaz. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Oceânica. III. Título.

*À minha família,  
minha força inabalável para prosseguir.*

## **Agradecimentos**

A Deus por me capacitar.

Aos meus pais, minha base e sustentação, que acreditaram desde cedo que a educação é a principal ferramenta para a conquista dos nossos sonhos.

À minha esposa Ana Carolina, sem a qual o caminho seria muito mais difícil. Obrigado por cada momento de suporte e incentivo.

Aos meus irmãos, minhas tias, primos e amigos mais próximos que sempre tinham palavras de encorajamento e carinho.

À Marinha do Brasil, pelo programa de incentivo ao estudo avançado de seus militares e servidores.

À toda equipe do LEDAV. Professores e servidores dos quais me orgulho muito de terem dividido seus conhecimentos e, principalmente, pelos conselhos dados ao longo dessa jornada. Professores Luiz Vaz, Ulisses, Homero, Troyman, Dionísio e Brenno, meus mais sinceros agradecimentos.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para obtenção do grau de Mestre em Ciências (M.Sc.)

## APLICAÇÃO DE APRENDIZAGEM DE MÁQUINA NO ALINHAMENTO DE EIXO PROPULSOR DE NAVIOS

Diego Landim Magalhães

Abril/2023

Orientador: Luiz Antônio Vaz Pinto

Programa: Engenharia Oceânica

O alinhamento dos eixos dos navios é crucial para a obtenção do melhor desempenho do sistema propulsivo, sendo realizado em dique seco através de ajustes dos recalques dos mancais, no entanto, definir um conjunto ótimo destes recalques demanda, atualmente, tempo de execução e custos operacionais elevados.

Nesse sentido, esta dissertação propõe o uso de modelos de aprendizado de máquina para prever o conjunto adequado dos valores dos recalques, seguindo as regras mandatórias em vigor, que retornem uma configuração de linha de eixo corretamente alinhada. Desta forma, desenvolveu-se uma metodologia segundo a qual, implementou-se um modelo de elementos finitos da linha de eixo propulsor de um navio *Anchor Handling Tug Supply (AHTS)*, utilizado como estudo de caso, onde tornou-se possível a obtenção das informações necessárias para a criação do banco de dados e posterior implementação dos modelos de aprendizado de máquina.

Os resultados apontaram que os algoritmos *Gradient Boosting*, *Random Forest* e Redes Neurais Profundas obtiveram os melhores resultados, alcançando valores de até 98,14% de precisão, com valores de precisão médias superiores a 96,00%. Desta forma, os modelos criados foram julgados confiáveis e capazes de serem utilizados nos procedimentos de alinhamento de eixos principais.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

## MACHINE LEARNING APPLICATION IN THE PROPELLER SHAFT ALIGNMENT OF VESSELS

Diego Landim Magalhães

April/2023

Advisor: Luiz Antônio Vaz Pinto

Department: Ocean Engineering

Ship' shaft alignment is crucial for obtaining a better performance of its propulsion system. This alignment is ensured, yet in the drydock, by adjusting the bearings' offsets. However, to define an optimum set of vertical displacements it can cost a valuable time for the shipyards.

Therefore, this work proposes the use of machine learning (ML) algorithms to predict the suitable set of offsets, following the mandatory rules in force. Thus, a methodology was developed according to which a finite elements model of shaft line of an Anchor Handling Tug Supply (AHTS) ship was assembled to obtain the reactions in the bearings, shaft line deflections, shear forces, bending moments and, at last, the influence coefficients matrix (ICM), and so allowing the dataset creation and the ML models implementation.

Results showed that Gradient Boosting, Random Forest and Deep Neural Networks algorithms presented the best results, achieving up to 98.14% of precision in one of the several scenarios tested, and an average precision of around 96.00%, contributing to make quicker the nowadays very time-consuming process of shaft alignment. In this way, the models created were judged to be reliable and capable of being used in the main shaft alignment' procedures.

## Sumário

1. Introdução.....	1
1.1. Motivação .....	2
1.2. Objetivos .....	3
2. Revisão Bibliográfica .....	4
2.1. Sistemas de Eixo Principal .....	4
2.2. Aprendizagem de máquina.....	5
2.2.1. Métrica de avaliação.....	7
2.2.2. Técnicas de sub e superamostragem .....	7
2.3. Algoritmos de ML selecionados .....	9
2.3.1. <i>Extremely Randomized Trees</i> (Árvores Extremamente Aleatórias).....	10
2.3.2. <i>Random Forest</i> (Floresta Aleatória).....	10
2.3.3. <i>Gradient Boosting</i> (Aumento de Gradiente) .....	11
2.3.4. <i>Deep Artificial Neural Networks</i> (Redes Neurais Artificiais Profundas)...	12
3. Fundamentos Teóricos .....	15
3.1. Descrição do eixo propulsor .....	15
3.2. Funções Principais .....	17
3.3. Importância do alinhamento.....	17
3.3.1. Alinhamento da engrenagem redutora ou do acionador .....	18
3.3.2. Sobrecarregamento ou descarregamento dos mancais.....	18
3.3.3. Vibração excessiva.....	19
3.3.4. Prevenção à tensão de flexão excessiva .....	19
3.4. Fatores que afetam o alinhamento .....	19
3.4.1. Deflexão da estrutura do casco .....	19
3.4.2. Dilatação ou contração térmica .....	20
3.4.3. Desgaste dos mancais do tubo telescópico .....	20
3.4.4. Alinhamento em dique seco versus flutuando.....	21
3.4.5. Condições de carregamento: lastro, carga paga e combustível .....	21
3.4.6. Projeto do navio e do sistema propulsivo.....	22



3.4.7.	Efeitos hidrodinâmicos do propulsor e inclinação do furo do TT .....	22
3.4.8.	Velocidade e potência do navio .....	23
3.4.9.	Deflexões do mancal de escora e sua fundação.....	23
3.5.	Principais formas de predição de problemas .....	23
3.5.1.	Medição das temperaturas dos mancais.....	23
3.5.2.	Análise de vibração .....	24
3.5.3.	Medições das reações nos mancais .....	24
3.6.	Regras de alinhamento do sistema de eixo .....	26
4.	Metodologia .....	29
4.1.	Matriz dos coeficientes de influência (MCI).....	30
4.2.	Regras de classificação da variável alvo .....	33
5.	Estudo de Caso .....	35
5.1.	Linha de eixo analisada .....	35
5.2.	Modelagem da linha de eixo .....	38
5.3.	Bancos de Dados .....	40
5.3.1.	Banco de dados 1 – 800 amostras balanceadas .....	41
5.3.2.	Banco de dados 2 – 1600 amostras balanceadas .....	42
5.3.3.	Banco de dados 3 – 1678 amostras desbalanceadas.....	42
5.4.	Condições analisadas.....	43
5.4.1.	Condição 1 - navio docado .....	43
5.4.2.	Condição 2 - navio frio.....	44
5.4.3.	Condição 3 - navio quente .....	44
5.5.	Variáveis preditoras e alvo.....	45
5.6.	Pré-processamento e seleção de variáveis.....	47
6.	Resultados e Discussões.....	51
6.1.	Resultados dos modelos de ML.....	51
6.1.1.	<i>Extremely randomized trees</i> .....	51
6.1.2.	<i>Random Forest (RF)</i> .....	53
6.1.3.	<i>Gradient Boosting (GB)</i> .....	54

6.2. Resultados das Redes Neurais Profundas .....	55
6.2.1. <i>Adam</i> .....	57
6.2.2. <i>RMSprop</i> .....	60
6.2.3. <i>Gradiente estocástico descendente (SGD)</i> .....	62
7. Conclusões e Recomendações .....	66
7.1. Trabalhos Futuros.....	69
8. Referências Bibliográficas .....	70
Apêndice A – Métricas de Avaliação.....	74
A.1 Acurácia ( <i>Accuracy</i> ).....	74
A.2 Precisão ( <i>Precision</i> ).....	75
A.3 Revocação ou Sensibilidade ( <i>Recall</i> ).....	76
A.4 <i>F1-Score</i> .....	78
Apêndice B – Índices Gini e Entropia.....	79
B.1 Índice Gini.....	79
B.2 Índice Entropia.....	79
Apêndice C – Funções de Ativação .....	80
C.1 Função <i>Rectified Linear Unit (ReLU)</i> .....	80
C.2 Função <i>Softmax</i> .....	81

## Lista de Figuras

Figura 1: Diagrama esquemático do aprendizado supervisionado .....	6
Figura 2: Rede Neural Artificial – (“Deep Learning Book”, 2022).....	12
Figura 3: Sistema de linha de eixo com Motor-Propulsor diretamente acoplados – (AMERICAN BUREAU OF SHIPPING, 2019) .....	15
Figura 4: Método do macaco hidráulico - (AMERICAN BUREAU OF SHIPPING, 2019) .....	25
Figura 5: Medidores de deformação (AMERICAN BUREAU OF SHIPPING, 2019) ....	25
Figura 6: Fluxograma da Metodologia empregada.....	30
Figura 7: Navio AHTS analisado no estudo de caso .....	36
Figura 8: Linha de Eixo estudada.....	37
Figura 9: Nós e Elementos da LE – Interface MetRig.....	38
Figura 10: Saída gráfica dos resultados obtidos do software MetRig .....	39
Figura 11: Variáveis Predictoras e Alvo (“Regra Final”) .....	45
Figura 12: Mapa de Calor das variáveis predictoras após as primeiras exclusões.....	48
Figura 13: Mapa de Calor das variáveis predictoras remanescentes .....	49
Figura 14: Otimizador Adam .....	58
Figura 15: Otimizador Adam com regularização L2 e Dropout .....	59
Figura 16: Otimizador RMSprop .....	61
Figura 17: Otimizador RMSprop com regularização L2 e Dropout .....	62
Figura 18: Otimizador SGD.....	63
Figura 19: SGD com regularização L2 e Dropout.....	64
Figura 20: Comparação dos melhores resultados de cada modelo.....	66
Figura 21: Acurácia a partir da matriz de confusão – Valores obtidos com o modelo refinado de GB – Condição 1 – banco de dados 2.....	75
Figura 22: Precisão a partir da matriz de confusão da classe “Ótimo” .....	76
Figura 23: Revocação a partir da matriz de confusão da classe “Ruim’ .....	77
Figura 24: Função de ativação $ReLU(x)$ .....	81

## Lista de Tabelas

Tabela 1: Matriz dos coeficientes de influência (valores em N/mm) .....	31
Tabela 2: Resumo dos dados da linha de eixo analisada .....	36
Tabela 3: Resumo das análises testadas.....	45
Tabela 4: Banco de dados 1 pós-processado .....	50
Tabela 5: Resultados – modelos de Extra-trees.....	52
Tabela 6: Resultados – modelos de Random Forest.....	53
Tabela 7: Resultados – modelos GB.....	54
Tabela 8: Resultados do otimizador Adam.....	57
Tabela 9: Resultados Adam + Regularização L2 e Dropout.....	59
Tabela 10: Resultados otimizador RMSprop .....	60
Tabela 11: Resultados RMSprop + Regularização L2 e Dropout .....	61
Tabela 12: Resultados otimizador SGD .....	63
Tabela 13: Resultados SGD + Regularização L2 e Dropout .....	64
Tabela 14: Média das precisões por banco de dados e algoritmo.....	67

## Lista de Símbolos

$E$  – módulo de elasticidade longitudinal do material;

$G$  – módulo de elasticidade transversal do material;

$L$  – comprimento da linha de eixo;

$p_j$  – probabilidade da classe  $j$  em um nó da árvore

$\nu$  – coeficiente de Poisson do material;

$\rho_{aço}$  – densidade do Aço ASTM1045, material da linha de eixo analisada;

$\rho_{as}$  – densidade da água salgada;

$\rho_{óleo}$  – densidade do óleo lubrificante;

$\sigma_e$  – tensão de escoamento do material.

## Lista de Abreviações

AHTS – Rebocador para Manuseio de Âncoras e Suprimento (*Anchor Handling Tug Supply*);

CART – Árvores de Classificação e Regressão (*Classification and Regression Trees*);

COPPE – Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia;

Eq. – Equação;

FN – Falsos negativos (*False Negatives*);

FP – Falsos positivos (*False Positives*);

GB – Aumento de Gradiente (*Gradient Boosting*);

GT – Tonelagem bruta (*Gross Tonnage*);

IA – Inteligência Artificial;

$L$  – Comprimento (*Length*);

LE – Linha de Eixo;

LEDAV – Laboratório de Ensaio Dinâmico e Análise de Vibrações;

MCI – Matriz dos Coeficientes de Influência;

MCP – Motor de Combustão Principal;

ML – Aprendizado de Máquina (*Machine Learning*);

PM – Praça de Máquinas;

RELU – Unidade Linear Retificada (*Rectified Linear Unit*);

RF – Floresta Aleatória (*Random Forest*);

RN – Rede Neural (*Neural Network*);

SGD – Gradiente Descendente Estocástico (*Stochastic Gradient Descent*);

SNAME – Sociedade dos Arquitetos e Engenheiros Navais (*Society of Naval Architects and Marine Engineers*);

TT – Tubo Telescópico (*Stern Tube*);

VN – Verdadeiros Negativos (*True Negatives*);

VP – Verdadeiros Positivos (*True Positives*).

# 1. Introdução

Navios de grande porte compõem a maior parte da frota mundial empregadas no transporte de cargas, principalmente, no que diz respeito às transações comerciais internacionais. O sistema de propulsão dessas embarcações mais comumente utilizado é aquele que utiliza a transmissão mecânica. Neste tipo de sistema, as linhas de eixo (LE), podem ser divididas em seções de diâmetros distintos, que costumam ser conectados por flanges ou luvas e têm seu peso e alinhamento assegurados pelos mancais de sustentação. Assim sendo, ressalta-se a importância dos posicionamentos verticais dos mancais, também chamados de recalques ou *offsets*, para a garantia de um sistema propulsivo corretamente alinhado (SNAME, 2007).

Devido ao alto grau de importância dos sistemas propulsivos para a operação e segurança de uma determinada embarcação, recai também sobre os sistemas de eixos de propulsão principal, a necessidade de um alto grau de confiabilidade, uma vez que uma eventual perda deste sistema resultará em grandes problemas à segurança do navio, à sua carga, ao meio ambiente e, principalmente, à sua tripulação.

Desta maneira, após o processo de seleção da configuração da LE, onde detalham-se suas seções, seleciona(m)-se seu(s) material(ais) e, definem-se a quantidade e as dimensões dos mancais, executa-se o seu alinhamento estático. Este processo é realizado, com os navios ainda em dique seco e, com eventuais ajustes já com a embarcação flutuando em águas tranquilas.

O processo de alinhamento é realizado ajustando-se os recalques dos mancais e, findada esta etapa, analisam-se os esforços (reações, pressões, esforços cortantes, momentos fletores, inclinações, etc.) aos quais estes e a LE estão submetidos. Determinadas condições críticas de operação (totalmente carregada, em lastro, navio “quente”, etc.) devem ser levadas em consideração, verificando se o conjunto de recalques testado retorna reações nos mancais satisfatórias atendendo às normas que regem o correto processo de alinhamento. No caso estudado, para o correto alinhamento dos sistemas de eixo de propulsão principal foi utilizada a referência (SNAME, 2007).

O supracitado conjunto de recalques pode retornar valores de reações que convirjam para um sistema confiável, todavia, há ainda maior número de conjuntos que retornarão reações impróprias ao bom funcionamento do sistema de eixo. Na prática, observa-se, atualmente, em muitos estaleiros, a utilização da técnica de tentativa e erro,

augmentando e diminuindo os recalques das LE representadas em *softwares*, até que as medições estejam atendendo às regras para aquela determinada embarcação e condição. Tal prática torna o processo mais demorado, trabalhoso, ineficiente e caro, como o citado nos trabalhos de (DUARTE, BAPTISTA, *et al.*, 2021, ŠVERKO, 2003a).

## 1.1. Motivação

Nesse contexto, decidiu-se pela aplicação dos algoritmos de aprendizagem de máquina (*Machine Learning - ML*) para verificar se um determinado conjunto de recalques retorna valores “ótimos”, “bons”, “regulares”, ou “ruins”, quando comparados às regras de alinhamento estático mandatórias (SNAME, 2007). Assim sendo, o alinhamento de um determinado eixo de propulsão principal pôde ser analisado como um problema de aprendizado supervisionado multiclases onde, aproveitando-se um conjunto de recalques classificado como “ótimo” e aplicando-o aos mancais, obter-se-ia um sistema corretamente alinhado. Este é, portanto, o principal objetivo desta dissertação.

À vista do apresentado, definiu-se, então, como sendo a criação de ao menos um modelo, com valores de precisão acima dos 95,00%, os objetivos e contribuições principais desta dissertação, tratando-se de uma abordagem ainda não vista em trabalhos e artigos voltados para o alinhamento de eixos de propulsão principal.

Desta maneira, bancos de dados para uma determinada configuração de LE, de um navio *AHTS*, foram criados. Por se tratar de dados inteiramente novos, outro enfoque desta dissertação residiu na comparação de quais algoritmos de ML, melhor se adaptariam a estes bancos, fornecendo assim, modelos com melhores *Precisões*.

Finalmente, destaca-se que, na busca de um classificador de conjuntos de recalques, o processo de alinhamento de eixos pode ser realizado de maneira mais ordenada e orientada, ao invés do processo quase aleatório observado atualmente. O desenvolvimento de tal técnica, através das ferramentas de inteligência artificial (IA) e ML, utilizando-se o melhor modelo testado, trata-se de uma abordagem inovadora, com significativo potencial de implementação nos trabalhos práticos encontrados diariamente em estaleiros de todo o mundo.



## 1.2. Objetivos

Definidos os pontos que motivaram a execução dessa dissertação, os objetivos principais também puderam ser determinados. Resumidamente, os mais importantes deles são apresentados abaixo:

- ✓ Elaboração de uma nova metodologia buscando a otimização do processo de alinhamento do sistema de eixo principal de navios;
- ✓ Criação de modelos capazes de indicar se um determinado conjunto de recalques deve ou não ser aplicado a um determinado sistema de linha de eixo (LE) de propulsão principal;
- ✓ Verificação de qual modelo de aprendizagem de máquina obtém a melhor performance para os bancos de dados criados; e
- ✓ Fornecimento/criação de uma nova forma/ferramenta à indústria naval, capaz de acelerar o processo de alinhamento do sistema de linhas de eixos de embarcações.

A partir de tais objetivos, os estudos apresentados a seguir se desenvolveram buscando-se atendê-los bem como de aplicá-los como forma de corrigir ineficiências observadas no processo de alinhamento do sistema de linha de eixo principal. Neste contexto, apresenta-se no próximo capítulo a revisão bibliográfica dos trabalhos acadêmicos da mais alta relevância que nortearam o trabalho desenvolvido.

## 2. Revisão Bibliográfica

Analisando-se os artigos científicos mais relevantes dos últimos anos, observaram-se duas principais contribuições no que tange o desenvolvimento dos estudos elaborados neste trabalho.

A primeira aborda conceitos relacionados aos procedimentos e cenários observados nos sistemas de LE principal dos navios, onde destaca-se a observação de um aumento significativo de falhas e de intercorrências, principalmente nas embarcações mais novas (LEE, Young-Jin, KIM, *et al.*, 2006, ŠVERKO, 2003a). Tais problemas estão associados à tendência observada de navios cada vez mais esbeltos (razão comprimento-boca muito elevada), e, portanto, à cascos muito flexíveis. Em contrapartida, os eixos estão cada vez mais rígidos, tanto pelo aumento de seus diâmetros quanto pela redução dos vãos entre mancais. Desta forma, o sistema de LE propulsor acaba se tornando menos complacente, origem da maioria dos problemas de alinhamento observados.

Já a segunda, apresenta os conceitos e fundamentos que compõem o ramo de ML, esclarecendo-se suas principais utilizações, e também, os resultados e aplicações de sucesso já implementados nas mais variadas áreas de interesse (OUADAH, ZEMMOUCHI-GHOMARI, *et al.*, 2022).

Ambas as contribuições foram analisadas e os principais fundamentos que puderam ser aproveitados são apresentados nas subseções a seguir. Foram estas, portanto, as bases que sustentaram os novos conceitos elaborados nessa dissertação, resultando nos modelos/classificadores que serão apresentados nos capítulos que se seguem.

### 2.1. Sistemas de Eixo Principal

Considerando o *Estado da Arte* das últimas publicações acadêmicas, analisaram-se os artigos produzidos no intervalo dos últimos cinco anos, (CHOI, LEE, *et al.*, 2021, LEE, Jae ung, 2018, LEE, Jae ung, JEONG, *et al.*, 2019, SEO, JEONG, *et al.*, 2020), onde todos constataram o aumento dos problemas nos sistemas de eixo, principalmente, em virtude das maiores deflexões dos cascos, dos efeitos das dilatações térmicas nos mancais da LE, e da constatação do aumento da rigidez dos eixos.

Entre as principais contribuições destes artigos, destacam-se observações de cenários onde as praças de máquinas (PM) se deformam em sentido contrário ao

experimentado pelo navio em sua seção média. Isto é, constataram-se casos em que as praças de máquinas estavam na condição de toçamento enquanto a viga navio era submetida a condição de alquebramento, e vice-versa (SEO, JEONG, *et al.*, 2020).

Outra constatação residiu no fato da força exercida pelo propulsor, com o navio navegando a vante, muitas das vezes, ter uma força no sentido de baixo para cima, podendo assim aumentar a sustentação, reduzindo as cargas a serem suportadas pelo mancão mais a ré da LE (LEE, Jae ung, 2018).

Observou-se ainda, que os estudos seguiram dois caminhos principais. O primeiro deles foi o processo de representação dos reforços estruturais dos navios em elementos finitos, com um refinamento especial na região da PM. Já o segundo, foi a observação *in-loco* com medições de reações e deformações realizadas com o navio em operação, em diferentes condições de carregamento, e ainda com a LE parada (análise estática), na maioria das vezes.

Ambas as abordagens têm seus prós e contras, uma vez que a primeira se trata de um processo que requer um tempo considerável para ser executada, além de uma equipe multidisciplinar dedicada exclusivamente para esse estudo. Já a segunda, requer que um determinado navio fique à disposição para as medições necessárias e muitas das vezes, os resultados obtidos acaba não podendo ser replicado a navios de outras classes, em virtude das diferenças estruturais observadas nas PM's e também das diferentes condições de carregamento às quais os navios estão submetidos.

Em resumo, conclui-se que, idealmente, a união dos dois métodos, analisando-se uma gama extensa de navios e de condições de carregamento, seria a melhor forma de obtenção de resultados mais confiáveis e replicáveis para outros navios.

## 2.2. Aprendizagem de máquina

O termo aprendizagem de máquina pode ser definido, de maneira sucinta, como uma técnica dentro da área de Inteligência Artificial (IA), onde máquinas tornam-se capazes de, a partir de um banco de dados coeso, executar determinada(s) função(ões), de maneira inteligente, com base no seu autoaprendizado, com infinitas possibilidades de aplicação (LANTZ, 2013, MÜLLER, GUIDO, 2016).

Observa-se que no campo de problemas solucionados com as ferramentas de ML, existem basicamente dois tipos de problemas: os de regressão e os de classificação,

sendo este último o abordado nesta dissertação. O estudo apresentado se desenvolveu como um problema de classificação multiclasse, uma vez que a predição esperada dos modelos retorna uma dentre 4 classes, ao término de sua execução.

Trata-se ainda de um tipo específico de aprendizagem de máquina, a chamada aprendizagem supervisionada. Tal abordagem se desenvolve de maneira em que se treina o algoritmo a partir de rótulos (*labels*) já definidos. Ou seja, o algoritmo já sabe a solução e, neste contexto, torna-se possível comparar os resultados obtidos com os dados corretos, utilizando-se o conceito de dados de treino e de teste, por exemplo. A Figura 1, sintetiza os passos dados quando da aplicação de tal tipo de aprendizado.

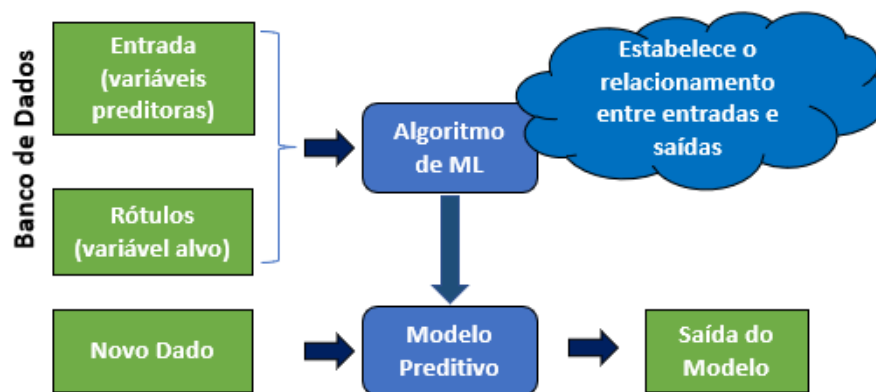


Figura 1: Diagrama esquemático do aprendizado supervisionado

Diversos algoritmos já foram desenvolvidos ao longo dos últimos anos e atendem a diversas situações análogas às citadas acima e o sucesso de suas aplicações depende da área de estudo que está sendo analisada. Todavia, a confirmação de qual algoritmo retornará os melhores resultados de predição só se provará testando-se alguns deles para o mesmo banco de dados e, a partir de uma métrica de avaliação definida, verificando-se quais retornam os melhores valores.

Outrossim, destacam-se as etapas que compõem problemas de ML, as quais são geralmente divididas em:

- i. Conhecimento dos dados à disposição e do problema que se deseja resolver;
- ii. Determinação do(s) banco(s) de dados;
- iii. Pré-processamento e seleção de variáveis;
- iv. Aplicação do modelo (algoritmo) de ML;
- v. Medição dos resultados;
- vi. Refinamento (variação dos hiperparâmetros do algoritmo); e
- vii. Objetivo x Resultados.

As etapas de elaboração dos bancos de dados e dos modelos de ML, são apresentadas nas seções 5.1, 5.2 e 4.1 e 5.3, e o posterior pré-processamento e medição de resultados, nas seções 5.6, 6.1 e 6.2. Essas etapas detalham o desenvolvimento de cada um dos sete itens mencionados acima.

### 2.2.1. Métrica de avaliação

Uma vez que se pretende aproveitar apenas algum dos conjuntos de recalques classificados como “ótimos”, tal como o mencionado no capítulo 1, descartando-se os demais conjuntos, é de máxima importância obter-se o mínimo possível de valores falsos positivos (FP) (MHAWISH, GUPTA, 2020, MÜLLER, GUIDO, 2016). Ou seja, os modelos que prevejam um conjunto de recalques como “ótimo” de maneira equivocada, devem ser evitados ao máximo, uma vez que estes poderão acarretar sistemas de eixo desalinhados, podendo até mesmo impactar o sistema de propulsão como um todo.

Nestes termos, e considerando-se os detalhes apresentados no Apêndice A – Métricas de Avaliação, a métrica “*Precisão*” foi a considerada como sendo a mais importante para classificar quais modelos obtiveram melhores resultados. Uma vez que tal métrica é regida pela equação (A.2), pode-se observar que quanto menor forem os valores FP’s, maiores valores de precisão serão obtidos.

As demais métricas também são apresentadas no Apêndice A – Métricas de Avaliação, uma vez que alguns modelos foram elaborados criando-se um relatório de classificação onde tais métricas são obtidas juntamente com a Precisão e, portanto, foi julgado importante a apresentação do cálculo das mesmas.

### 2.2.2. Técnicas de sub e superamostragem

Bancos de dados desbalanceados, ou seja, onde determinada classe sobressai consideravelmente em detrimento das demais, ou ainda, quando observa-se uma classe substancialmente com menor número de amostras que as demais, configuram dois cenários muito comuns no processo de obtenção de banco de dados confiáveis, principalmente em problemas relacionados às áreas de engenharia. Um exemplo que pode ilustrar tal situação, reside na análise de peças de uma linha de produção, onde espera-se que o número de amostras *defeituosas* seja consideravelmente menor do que

o de peças *normais*. Observou-se que tais cenários podem trazer severos prejuízos aos desempenhos de modelos de ML caso os devidos cuidados não sejam tomados (CHAWLA, BOWYER, *et al.*, 2002).

Neste contexto, técnicas de subamostragem, para o primeiro cenário, e, de superamostragem, para o segundo, são comumente empregadas, ainda na etapa de pré-processamento, como forma de mitigar problemas futuros nos resultados dos modelos criados (MARTINS, DE LIMA, *et al.*, 2022).

O trabalho desenvolvido apresentou ambos os cenários. Modelos classificados como “ótimos” e “bons” sofriam do problema de subamostragem, enquanto os modelos “regulares” e, principalmente, os “ruins”, do cenário de superamostragem. Para combater tais problemas, duas técnicas foram aplicadas e seus conceitos principais são apresentados a seguir.

✓ *Synthetic Minority Over-sampling (SMOTE)*

A técnica de superamostragem utilizada foi a *Synthetic Minority Over-sampling Technique (SMOTE)* apresentado por (CHAWLA, BOWYER, *et al.*, 2002) e, pela qual dados sintéticos, classificados de forma análoga às amostras que se deseja aumentar, são criados e adicionados ao banco.

Esta ferramenta permite, através da sintetização de novas amostras da classe minoritária, baseando-se nas amostras desta classe já pertencentes ao banco de dados, e, assim, torna-se possível a criação de bancos de dados mais homogêneos, com menos probabilidade de se obter resultados enviesados.

Desta forma, as amostras classificadas como ótimas foram separadas e, variou-se ligeiramente em poucos milímetros (não mais que  $\pm 3$  milímetros em um determinado mancal) os valores de recalques de alguns mancais. Desta forma, conseguiu-se obter maiores quantidades das amostras que estavam defasadas das demais classes.

Ressalta-se, que os novos valores obtidos de maneira sintética, tal qual o preconizado na técnica do *SMOTE*, foram analisados e que se trata de amostras passíveis de serem encontradas no sistema de LE em estudo.

✓ *Exclusão aleatória*

Já no processo de subamostragem, a técnica utilizada foi a exclusão aleatória das amostras dominantes, também citada no trabalho de (CHAWLA, BOWYER, *et al.*, 2002), onde ambas as técnicas, *exclusão aleatória* e *SMOTE*, quando aplicadas de maneira

conjuntas, retornam melhores resultados do que quando apenas uma delas foi implementada.

Desse modo, as amostras classificadas como “regulares” e “ruins” foram excluídas de maneira aleatória, de tal forma que, após o processo de superamostragem das demais classes, elas estivessem em valores próximos umas das outras.

Ao término das implementações dessas técnicas, os bancos de dados que foram testados foram obtidos. Todas suas características e peculiaridades são detalhadas na seção 5.3 e suas subseções.

Por fim, selecionaram-se quatro algoritmos para que, ao receberem as informações dos bancos de dados, realizem a predição/classificação de um novo conjunto de recalques, permitindo assim, de maneira guiada e eficiente, obter um sistema de LE alinhado. Apresentam-se agora tais algoritmos que foram aplicados nas simulações realizadas.

### 2.3. Algoritmos de ML selecionados

Uma breve apresentação de cada modelo testado é feita a seguir. No entanto, cabe ressaltar que em todos os algoritmos analisados, houve a separação das amostras em dados de treino (80% das amostras) e de teste (20%), uma vez que, com esta separação, tenta-se diminuir o problema de sobreajuste (*overfitting*) que naturalmente ocorreria caso o modelo fosse elaborado baseando-se em todas as amostras. Tais valores destinados a treino e teste são valores costumeiramente usados nos problemas de aprendizado de máquina tal qual o apresentado em (NAKATSU, 2021).

O problema de sobreajuste citado acima, torna o modelo muito bom para os dados de treinamento, mas muito menos assertivo quando submetido a novos dados, nunca vistos pelo modelo, que são os chamados dados de teste. Precauções em relação a esse problema foram tomadas durante a elaboração dos códigos de cada um dos modelos analisados. Desde “embaralhamento” (*shuffle*) das amostras, separações em pastas (*folds*) para comparação com os resultados obtidos com a técnica de separação em dados de treino e teste (*hold-out*), sempre buscando-se a obtenção de modelos mais generalistas e menos enviesados. Isto esclarecido, apresentam-se agora, os algoritmos utilizados na elaboração desta dissertação.

### 2.3.1. *Extremely Randomized Trees* (Árvores Extremamente Aleatórias)

O algoritmo *extremely randomized trees* ou *extra-trees* utiliza o método *ensemble*. Este método constrói uma série de algoritmos e então, o resultado agregado é selecionado como o resultado final. São geralmente modelos que demandam maior recurso computacional por serem algoritmos mais robustos, mas que, no entanto, tendem a retornar bons resultados de predições (CHENG, WU, *et al.*, 2021, ESLAMI, SALMAN, *et al.*, 2020), sendo por isso, um dos modelos testados nesse estudo.

Trata-se, de um modelo recomendado para trabalhar-se com problemas de ML multiclasse, tal qual o apresentado em (GEURTS, ERNST, *et al.*, 2006). Resumidamente, as *extra-trees*, inspiradas no algoritmo de árvore de decisão, selecionam aleatoriamente um determinado número de variáveis preditoras – tantas quanto o cientista de dados julgar o suficiente – e, em seguida seleciona-se, também aleatoriamente, o ponto de corte dividindo a árvore em ramos. A partir daí o modelo escolhe, utilizando-se um critério estabelecido (índices Gini ou Entropia, por exemplo, vide Apêndice B – Índices Gini e Entropia) para selecionar a melhor variável para o início do nó. Todas essas etapas aleatórias, são realizadas com o intuito de diminuir-se os problemas de sobreajuste (*overfitting*), buscando tornar-se o modelo mais generalizável.

Nos modelos testados nesse trabalho, outros atributos tais como, profundidade máxima da árvore, critérios de seleção da melhor variável e número mínimo de amostras por divisão, foram variados buscando-se resultados mais refinados e, portanto, mais confiáveis. Todas as faixas dos hiperparâmetros testados, na etapa de refinamento dos modelos, são apresentadas em detalhes no capítulo 6.

### 2.3.2. *Random Forest* (Floresta Aleatória)

O algoritmo de aprendizado de máquinas *Random Forest* também utiliza o robusto método *ensemble*, sendo apontado em (FERNÁNDEZ-DELGADO, CERNADAS, *et al.*, 2014) como, provavelmente, o melhor algoritmo classificador para um número considerável de conjuntos de dados estudados.

Também baseado no conceito de árvores de decisão, este algoritmo funciona selecionando-se aleatoriamente uma parte das amostras e das variáveis preditoras. Após essas seleções, o algoritmo calcula a melhor dessas variáveis (geralmente utilizando o índice Gini, ou o índice Entropia – vide Apêndice B – Índices Gini e Entropia)



para ser o primeiro nó (raiz) de uma das árvores. Esse processo repete-se tantas vezes quantas forem definidas pelo cientista de dados, e assim, é criado um igual número de árvores de decisão, cada uma delas diferente da outra, obtendo-se resultados de alto desempenho com o visto em (SALLES, GONÇALVES, et al., 2018, SHAH, PATEL, et al., 2020).

Diferentemente dos modelos de *extra-trees*, onde o ponto de corte (*threshold*) é escolhido de maneira aleatória, nos modelos de *Random Forest* este ponto é tal que o melhor dentre todas as combinações possíveis é o escolhido. Tal seleção é realizada pelo algoritmo *CART* (*Classification and Regression Trees*), responsável por testar todas as combinações possíveis de divisões, analisando-se as respectivas *funções de custo*. A divisão que retornar a menor *função de custo* é a escolhida como ponto de corte. Foi o *CART* o algoritmo adotado nos modelos de ML executados nessa dissertação. Criadas as árvores, efetua-se as predições por cada uma delas e a resposta será a média dos resultados apontados por todas as árvores em problemas de regressão, e a de maior probabilidade nos problemas de classificação.

Destaca-se que cada árvore é criada de forma bem diferente uma da outra, buscando-se, mais uma vez, modelos mais generalizáveis e menos tendenciosos, tal qual o apresentado em detalhes em (BREIMAN, 2001, MÜLLER, GUIDO, 2016), tentando melhorar problemas recorrentes em modelos de árvore de decisão.

### 2.3.3. *Gradient Boosting* (Aumento de Gradiente)

Outro algoritmo que utiliza o método *ensemble* é o de Aumento de Gradiente (*Gradient Boosting*), que também costuma apresentar bons resultados em problemas de classificação multiclases, sendo por isso, um dos algoritmos escolhidos para ser testado com os bancos de dados deste estudo (BLAGUS, LUSA, 2017, TABRIZCHI, TABRIZCHI, et al., 2020). Trata-se de um algoritmo de aprendizado de máquinas onde há uma taxa de aprendizado (*learning rate*) onde tenta-se obter, a cada rodada, menores erros até que as predições atinjam altas taxas de acerto. Ou seja, em cada etapa o algoritmo buscará reduções de erros, aprendendo com os passos anteriores e, tentando obter modelos menos enviesados, com predições mais confiáveis.

Referente ao refinamento deste modelo, variaram-se alguns hiperparâmetros tais como, número mínimo de amostras para o ponto de corte, número mínimo de amostras por folha e ainda a profundidade máxima das árvores. A taxa de aprendizado utilizada

nos modelos de GB foi de 0,1 e optou-se por não variar esta taxa, uma vez que os resultados obtidos com ela foram julgados satisfatórios.

Finalmente, destaca-se o número de árvores que, assim como os hiperparâmetros citados acima, também foi variado nos modelos que empregaram o método *ensemble*. Os detalhes de cada modelo são apresentados no capítulo 6.

#### 2.3.4. *Deep Artificial Neural Networks* (Redes Neurais Artificiais Profundas)

Os algoritmos de redes neurais, como já explicitado em seu nome, tentam emular as redes dos neurônios dos cérebros humanos, tendo estes, algo em torno de 85 bilhões de neurônios, como o apresentado em (“Deep Learning Book”, 2022, LANTZ, 2013). Ou seja, o conceito para o desenvolvimento de redes neurais artificiais foi inspirado nas redes neurais biológicas. Sendo assim, e de maneira resumida, os “neurônios artificiais” trabalham recebendo informações (dados de entrada), em seguida transmitem certas informações julgadas relevantes, geralmente para outras camadas (dependendo da profundidade e configuração da rede) para então, tomarem suas decisões.

Neste trabalho, utilizaram-se redes neurais sequenciais e densas (ou totalmente conectadas), que são aquelas em que a totalidade de neurônios de uma camada se conecta com toda a camada seguinte, e cada uma delas se conecta só com a da frente (“Deep Learning Book”, 2022), tal qual o apresentado pela Figura 2.

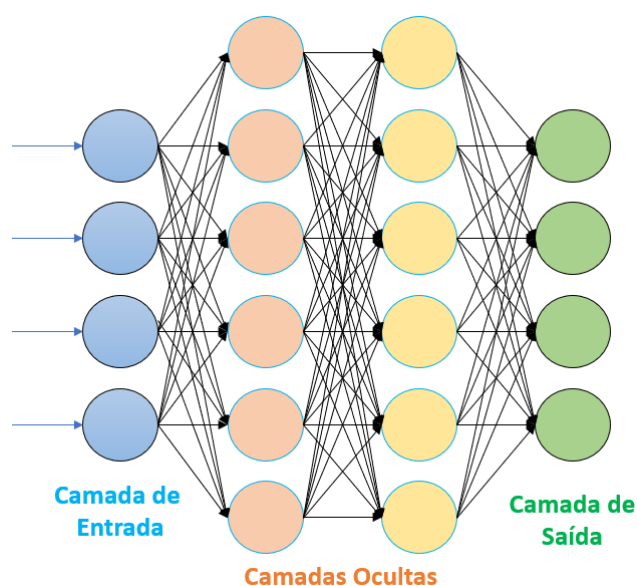


Figura 2: Rede Neural Artificial – (“Deep Learning Book”, 2022)

Ademais, variaram-se os otimizadores utilizados nestas redes para verificar em qual delas melhores resultados seriam encontrados, uma vez que cada um destes tem seus prós e contras e, por se tratar de um banco de dados novo, recomenda-se testar o desempenho em cada nova configuração da rede ou variação do otimizador empregado.

Desta maneira, os otimizadores escolhidos para os modelos a serem analisados foram o *Adam*, o *RMSprop* e, por fim, o *SGD (Stochastic Gradient Descent)*. Todos estes estão explicados em detalhes nas seções de suas respectivas aplicações e seguindo os conceitos apresentados na referência (KERAS, 2022).

O otimizador *Adam* trata-se de um método de gradiente estocástico descendente, baseado na estimativa adaptativa de momentos de primeira e segunda ordens (KERAS, 2022) sendo adequado para a resolução de problemas cujos dados ou parâmetros sejam “grandes” (KINGMA, BA, 2014). Entretanto, nas referências utilizadas não há uma definição exata a respeito de quantas amostras seriam necessárias para se configurar um banco de dados “grande”. Desta forma, resolveu-se testar e verificar se na prática, para o problema de classificação proposto, os resultados desse otimizador retornariam valores bons o suficiente para assegurar um modelo confiável.

Já o otimizador *RMSprop*, tenta limitar que se tenham gradientes estocásticos muito acentuados (KERAS, 2022), sejam eles muito grandes ou muito pequenos, partindo-se do pressuposto, de que nesses casos o caminho tomado está sendo o errado. Ou seja, este otimizador visa aumentar os passos em uma mesma direção, em busca do mínimo da função, sem um número excessivo de oscilações que são características marcantes do otimizador *SGD*. Por outro lado, ao limitarem-se os gradientes muito pequenos, por exemplo, pode haver uma demora maior de se atingir o mínimo da função de custo global e, podendo haver problemas relacionados a mínimos locais, tornando pobres os resultados de modelos promissores.

Por fim, o gradiente estocástico descendente (*stochastic gradient descent - SGD*) trabalha utilizando o mesmo conceito do gradiente descendente, onde a partir de uma função de custo, busca-se a atualização das variáveis de forma a reduzir tal função, utilizando-se os conceitos de derivadas parciais. A principal diferença do *SGD* para o Gradiente Descendente, é que as variáveis (pesos e *bias*) são ajustadas a partir de lotes do banco de dados, contendo apenas uma parte aleatória das amostras em cada época (iteração), reduzindo assim o custo computacional e o tempo despendido no processo iterativo de ajustagem destas variáveis, chegando, por fim, a valores bem próximos dos obtidos pelo gradiente descendente, só que de maneira mais rápida (AMARI, 1993, “Deep Learning Book”, 2022).

Sabe-se que as redes neurais artificiais profundas costumam sofrer com problemas de sobreajuste (“Deep Learning Book”, 2022), por conseguinte, medidas consagradas na literatura, tais como as técnicas de regularização e de *dropout* (técnica onde uma determinada quantidade de neurônios são desligados aleatoriamente, e propositalmente, gerando redes diferentes e mais robustas) foram implementadas aos modelos, tentando coibir-se esse problema que prejudica muito os resultados dos modelos.

Portanto, foram estes os quatro algoritmos testados nesta dissertação. Destacam-se as inúmeras variações realizadas nos parâmetros de cada um destes algoritmos quando do processo de refinamento. Tais variações resultaram na criação de vários modelos, tentando assim, abranger de forma fiel, grande parte das possibilidades de melhorias destes, cujos resultados principais serão apresentados no capítulo 6.

Outrossim, optou-se ainda pela análise dos resultados obtidos com os modelos de redes neurais profundas, uma vez que seus resultados são geralmente apresentados em função das épocas (iterações) e também verificando se os modelos estão sofrendo ou não de sobreajuste, de uma forma mais exclusiva e ilustrativa. Sendo assim, decidiu-se utilizar uma seção separada dos demais algoritmos para tais modelos, seção 6.2.

Desta maneira, no próximo capítulo apresentam-se os fundamentos teóricos que balizaram o desenvolvimento desta dissertação e que culminaram na elaboração dos modelos de ML capazes de classificar se determinado conjunto de recalques deve ou não ser aplicado à linha de eixo principal do navio analisado.

### 3. Fundamentos Teóricos

Neste capítulo abordam-se as principais características dos sistemas de propulsão e de linha de eixo de propulsão principal das embarcações. Analisa-se ainda, a importância do correto alinhamento destes sistemas, passando pelos fatores que contribuem para problemas relacionados ao desalinhamento.

Na sequência detalham-se as formas de predição destes problemas utilizadas atualmente e, por fim, apresentam-se as regras que devem ser respeitadas quando do processo de execução do alinhamento de uma determinada linha de eixo.

#### 3.1. Descrição do eixo propulsor

Os sistemas de propulsão principal de navios grandes com Tonelagem Bruta (*Gross Tonnage* - GT) na faixa de  $25.000 \leq GT \leq 59.999$  e muito grandes  $GT \geq 60.000$  são, em sua maior parte, sistemas compostos por acionadores, sejam eles motores e/ou turbinas, diretamente acoplados, Figura 3, ou ainda, conectados a uma engrenagem redutora, tendo na sua extremidade mais a ré, o propulsor (EQUASIS, 2020). Já o sistema de eixo (*shafting system*), é aquele responsável por fazer a transferência de torque oriundo dos acionadores ao propulsor.




Figura 3: Sistema de linha de eixo com Motor-Propulsor diretamente acoplados – (AMERICAN BUREAU OF SHIPPING, 2019)

As seções das LE que compõem o sistema de eixo são comumente nomeadas de acordo com a sua localização. Desse modo, denomina-se de *eixo propulsor*, a seção a qual o propulsor é montado; *eixo do tubo telescópico* (TT) aquela que passa por dentro do TT da embarcação. E, por fim, de *eixo intermediário*, aqueles que comunicam as

seções de eixo citadas anteriormente entre si ou, conectando o TT à caixa redutora, ou ainda, conectando os eixos do TT ao eixo de manivelas do acionador.

Compõem ainda o sistema de LE, os mancais, que, quando empregados para o suporte são geralmente classificados como de *deslizamento hidrodinâmico*, tendo estes uma bucha deslizante em seu interior e contam com uma cunha de óleo, para prover a sustentação do eixo. Os mancais podem ainda ser denominados conforme a linha de eixo que sustentam, de maneira análoga a explicada para a LE. Ainda em relação aos mancais, destaque é dado ao mancal de escora (*thrust bearing*), uma vez que é este o responsável por transferir o empuxo gerado pelo propulsor ao casco da embarcação.

Outros elementos que fazem parte do sistema estudado são os selos presentes nas extremidades do TT e em eventuais passagens que atravessam algumas anteparas transversais da PM, e visam assegurar a estanqueidade da embarcação no primeiro caso e, do compartimento respectivo quando do segundo.

Destaca-se que, diferentemente dos sistemas de eixos dos navios de médio e grande portes citados anteriormente, nos equipamentos industriais tradicionais que possuem, geralmente, comprimentos de eixos muito curtos e rígidos, o alinhamento ideal costumeiramente é obtido mantendo-se concêntricamente alinhados todos os mancais, ou seja, a partir de uma linha de base, todos os mancais terão seus recalques ajustados e concêntricamente alinhados. Tal suposição, no entanto, não se mostra válida na imensa maioria dos casos quando se trata de LE dos navios, uma vez que o suporte da linha se dá através de vários mancais e, estes acabam sofrendo diferentes deslocamentos verticais, em função da linha elástica do eixo. Ou seja, uma LE de uma determinada embarcação, estando com seus mancais concêntricamente alinhados, tende a retornar valores que não respeitam as normas de alinhamento em vigor (SNAME, 2007).

Outro fator, que corrobora para a variação entre os recalques dos mancais, é o fato de que as variadas cargas a que estes estão submetidos, como por exemplo os pesos do propulsor e da engrenagem redutora, atuam em regiões muito próximas de determinados mancais, mas ao mesmo tempo longe de outros.

Finalmente, a determinação de um conjunto de recalques dos mancais que contribuam para um correto alinhamento, considerando as variadas condições operacionais, torna-se uma missão árdua e que acaba por consumir um tempo relativamente grande (até dias chegam a ser gastos para alinhar uma LE), como o exposto nos trabalhos de (DUARTE, BAPTISTA, *et al.*, 2021, ŠVERKO, 2003b).

### 3.2. Funções Principais

Um eixo (*shaft*) pode ser definido, conforme o exposto em (BUDYNAS, NISBETT, *et al.*, 2011), como sendo um membro rotativo, geralmente de seção transversal circular variável, utilizado para a transmissão de potência ou rotação. Tal descrição define apropriadamente as atribuições do sistema de eixos de navios. No entanto, há outras funções principais pertinentes a este sistema que podem ser, segundo a publicação (SNAME, 2007), resumidas em:

- i. Transmitir a potência rotativa fornecida pelo(s) acionador(es), motor(es) e/ou turbina(s) para o propulsor;
- ii. Transmitir o empuxo produzido pelo propulsor ao casco do navio; e
- iii. Sustentar o peso do propulsor.

Em suma, um sistema de eixo de propulsão é aquele que conecta um dispositivo de acionamento à um propulsor, podendo este passar ou não por um dispositivo de aumento (multiplicadoras), caso mais raro em navios, ou de redução (reduzidoras) da rotação, sendo este, por fim, capaz de atender às três funções principais supracitadas.

### 3.3. Importância do alinhamento

Segundo a boletim técnico (SNAME, 2007), o sistema de eixo dos navios, pode ser considerado como uma viga exposta a cargas concentradas em vários pontos ao longo do seu comprimento, apoiada por mancais espaçados entre si. Diferentemente de eixos menores de sistemas industriais (PIOTROWSKI, JOHN, 2007), tais mancais são alinhados com seus recalques distintos uns dos outros, uma vez que eles são expostos à diferentes carregamentos e deformações (deflexões do casco, dilatações térmicas, etc.). Isto posto, destacam-se na sequência os seguintes pontos que, associados a um correto alinhamento, refletem uma condição mais confiável de operação.

### 3.3.1. Alinhamento da engrenagem redutora ou do acionador

Em obtendo-se um sistema de eixo alinhado, espera-se que tanto a engrenagem redutora, quando esta estiver presente, quanto o(s) motor(es)/turbina(s) se diretamente acoplados ao eixo, também estejam alinhados corretamente.

Desta forma, para verificar se de fato estes últimos elementos também estão alinhados, utilizam-se limites estabelecidos pelos fornecedores, ou na ausência de tais informações, regras estabelecidas por instituições de reconhecimento técnico altamente relevante, como a Sociedade dos Arquitetos e Engenheiros Navais (*Society of Naval Architects and Marine Engineers - SNAME*), ou ainda pelas sociedades classificadoras como a *American Bureau of Shipping (ABS)* e a *Det Norske Veritas (DNV)* (AMERICAN BUREAU OF SHIPPING, 2019, DNV GL, 2017), citando apenas essas duas que foram utilizadas nesta dissertação.

Em geral, costuma-se verificar se as cargas dos mancais a ré e a vante de tais elementos encontram-se dentro de valores aceitáveis e, em respeitando-se tais valores, espera-se configurações alinhadas. Ainda de acordo com a publicação (SNAME, 2007), um diferencial de carregamento excessivo nesses mancais pode produzir tensões severas e inaceitáveis nos dentes da engrenagem e, eventualmente causar desgaste severo, problemas associados à corrosão e também à fadiga dos materiais, em ambos os casos podendo chegar à fratura do material.

### 3.3.2. Sobrecarregamento ou descarregamento dos mancais

Cada um dos mancais de uma determinada linha de eixo tem suas especificidades, podendo variar em termos de material das suas buchas, tipo de lubrificação, tipo de fluido lubrificante, de função e etc.

Neste contexto, respeitando-se suas características, são estabelecidos limites máximos e mínimos de pressão que determinado mancal pode suportar. Para um sistema alinhado, há uma maior probabilidade de que esses limites sejam respeitados nas mais variadas condições de operação da embarcação. Desta maneira, buscando-se respeitar tais limites, costuma-se observar uma redução significativa dos problemas relacionados ao desgaste excessivo nestes mancais.



### 3.3.3. Vibração excessiva

Observa-se na prática que na presença de mancais descarregados, o vão entre dois mancais sucessivos se estende sensivelmente (SNAME, 2007). Neste caso, o vão passa a ser do comprimento entre os mancais a ré e a vante do mancal descarregado. Em casos como este, problemas relacionados a vibração lateral excessiva, impactam o sistema de eixo como um todo, trazendo consigo problemas de desgaste relacionados à fadiga.

### 3.3.4. Prevenção à tensão de flexão excessiva

De acordo com o relatório técnico (SNAME, 2007), o alinhamento tem um efeito direto sobre as tensões de flexão experimentadas pela LE. Um eixo desalinhado pode implicar em valores de tensão de flexão superiores às projetadas, levando a uma eventual falha do eixo, mais uma vez por problemas relacionados à fadiga.

## 3.4. Fatores que afetam o alinhamento

Conforme exposto anteriormente, determinar uma configuração que garanta que os sistemas de eixo principal de navios estejam alinhados pode vir a ser uma tarefa complicada, uma vez que estas têm grandes comprimentos e complexidade, e ainda existem muitos fatores que impactam este sistema, isto, por sua vez, torna-se muito sensível às pequenas modificações (ŠVERKO, 2005). Há casos em que pequenos incrementos ou decrementos nos recalques de determinado mancal, geralmente da ordem de milímetros, podem desalinhar o sistema como um todo. Deste modo, apresenta-se a seguir os principais fatores que podem vir a desalinhar o sistema de eixos (SNAME, 2007).

### 3.4.1. Deflexão da estrutura do casco

O cenário atualmente observado nos grandes navios (SEO, JEONG, *et al.*, 2020, ŠVERKO, 2003a) indica que eles estão cada vez mais flexíveis devido a seus

comprimentos cada vez maiores e também à otimização dos seus reforços estruturais e chapeamento dos cascos. Tal situação é observada, como explicado em (AMERICAN BUREAU OF SHIPPING, 2019), pois tenta-se cada vez mais reduzir o peso morto (*deadweight*) e, portanto, maximizar a capacidade de carga paga a ser transportada.

Em contrapartida, essas novas embarcações acabam por demandar uma alta potência dos motores e, estes, por sua vez, demandam eixos com diâmetros maiores para suportar o torque atuante. Nesse sentido, as LE vêm ficando mais rígidas e, desta forma, mais sensíveis às deformações experimentadas pelos cascos dessas embarcações.

#### 3.4.2. Dilatação ou contração térmica

Os fenômenos de dilatação e contração térmicas podem afetar o alinhamento do sistema propulsivo, uma vez que estes podem acarretar em modificações nos recalques dos mancais. No entanto, diferentemente do que se observa na deflexão do casco da embarcação, onde há um impacto em praticamente todos os mancais, problemas relacionados a uma significativa variação de temperatura costumam ser locais (AMERICAN BUREAU OF SHIPPING, 2019). Ou seja, tais problemas acabam por afetar apenas determinados mancais, seja pelo atrito do eixo com o mancal ou pela proximidade de fontes térmicas. Aqueles mais impactados são, geralmente, os mais próximos do(s) MCP(s) e da caixa redutora que são possíveis fontes de calor.

Variações térmicas no próprio eixo e também nos mancais do tubo telescópico são geralmente desprezíveis, uma vez que seus valores são pequenos quando comparados às estruturas próximas às fontes térmicas (SNAME, 2007).

#### 3.4.3. Desgaste dos mancais do tubo telescópico

Mancais posicionados fora do casco, são geralmente lubrificados a água, e, portanto, suas camisas ou calços experimentam um desgaste significativo. Ademais, seus recalques acabam por variar algumas vezes acima dos valores aceitáveis, podendo ocasionar o desalinhamento do eixo.

Em (SNAME, 2007) é ressaltado ainda que o alinhamento deve levar em consideração as eventuais mudanças de cargas nos mancais oriundas dos seus

desgastes. Por conseguinte, quando se efetua um correto alinhamento, deve-se considerar os valores aceitáveis de desgaste nos seus cálculos.

Geralmente, o desgaste desigual que os mancais externos experimentam, tendem a diminuir as cargas destes em detrimento de um aumento nos mancais internos, principalmente naqueles localizados mais à ré.

#### 3.4.4. Alinhamento em dique seco versus flutuando

O primeiro processo de alinhamento ocorre com os navios ainda emersos, assim, os resultados acabam variando quando estes passam à condição de flutuando, principalmente devido aos efeitos do empuxo presentes nessa condição, impactando na deflexão do casco, bem como na variação do peso do propulsor, por exemplo.

À vista desta situação, a publicação *Práticas e Procedimentos de Alinhamento de Sistemas de Eixo* (SNAME, 2007), recomenda uma verificação e ajustes finais ao alinhamento, quando da passagem de docado para a condição de calado de projeto e demais condições de carregamento a que o navio será submetido. Recomenda-se ainda um resguardo de aproximadamente dois dias para a realização de tais ajustes, como forma de respeitar-se a estabilização do casco na nova condição, e obter assim, uma maior confiança nesse procedimento.

#### 3.4.5. Condições de carregamento: lastro, carga paga e combustível

Costumeiramente observa-se que se negligenciam os efeitos impostos pelas cargas associadas ao combustível, ao lastro e ainda à carga paga da embarcação (AMERICAN BUREAU OF SHIPPING, 2019), esses efeitos variam muito de acordo com o tipo e tamanho do navio, bem como com o tipo de sistema de eixo empregado. Navios com uma gama de carregamentos grande costumam sofrer ainda mais com o fato de não serem levadas em consideração muitas dessas condições. Inclusive, cenários onde navios tiveram seus carregamentos limitados a menores condições do que foram projetados, como forma de seus sistemas propulsivos terem um desempenho aceitável (SNAME, 2007).

Deste modo, observa-se que o mínimo a se analisar, quando do procedimento de alinhamento do sistema de eixo, são as condições em que não haja carga alguma e, a de navio completamente carregado (SNAME, 2007).

Em contrapartida, o armazenamento de combustível afeta o alinhamento de maneira análoga às condições de carregamento total ou de navio em lastro. Recomenda-se que medições de alinhamento sejam realizadas para condições similares de carregamento de combustível sempre que possível. Uma regra geral da marinha americana é executar o alinhamento com 80% do total tanto de combustível quanto de carga (SNAME, 2007).

#### 3.4.6. Projeto do navio e do sistema propulsivo

Diferentes projetos/tipos de navios e de sistemas propulsivos, acabam por criar preocupações em relação ao alinhamento do sistema de eixo principal. Um exemplo aponta que sistemas propulsivos com engrenagens redutoras acabam tendo que respeitar critérios estabelecidos pelos seus fornecedores, principalmente relacionados a diferença de carga entre os mancais diretamente a vante e a ré da engrenagem (SNAME, 2007). Tais critérios são bem diferentes dos definidos para um sistema motor-propulsor diretamente acoplado, por exemplo.

#### 3.4.7. Efeitos hidrodinâmicos do propulsor e inclinação do furo do TT

A força hidrodinâmica de um propulsor em operação é descentralizada em relação à linha de centro do eixo propulsor (SNAME, 2007). Desta forma, tal excentricidade cria um momento que varia em magnitude e direção, e que depende principalmente da configuração da popa e do calado da embarcação. Desta forma, torna-se importante que o eixo continue em contato com a maior área de contato possível do mancal de ré do TT, uma vez que, se este ponto de contato se deslocar para vante, problemas de pancadas (*pounding*) podem acometer a linha de eixo, colocando em risco o seu correto alinhamento e sua operacionalidade.

### 3.4.8. Velocidade e potência do navio

Uma vez que a velocidade e a potência de um navio determinam a faixa de cargas de empuxo gerado pelo propulsor e, tendo este último um efeito significativo em como o eixo se assentará no mancal mais a ré, tais valores se tornam significativos para a faixa aceitável de alinhamento. Em algumas aplicações, o empuxo descentralizado pode até mesmo acabar afetando as cargas experimentadas pelos mancais (SNAME, 2007). Neste contexto, faz-se necessário levar em consideração os efeitos dinâmicos atrelados à velocidade e à potência das embarcações nas análises de alinhamento mais completas.

### 3.4.9. Deflexões do mancal de escora e sua fundação

Além de lidar com deflexões, os mancais de escora acabam sofrendo esforços de tração e compressão, de acordo com a força de empuxo aplicada à embarcação e também com o projeto de sua fundação (SNAME, 2007). Neste contexto, atenção deve ser dada, ainda na fase de projeto, para que as rigidezes das fundações desses mancais sejam tais que, essas deflexões sejam pequenas ou até mesmo insignificantes, não sendo capazes de retirar o sistema da sua configuração de corretamente alinhado.

## 3.5. Principais formas de predição de problemas

Devido à necessidade de se manter operativo o sistema de propulsão como um todo, essa necessidade também se aplica ao sistema de eixo principal, uma vez que ambos os sistemas têm uma correlação quase que direta. Nesse cenário, algumas medidas de acompanhamento do correto funcionamento devem ser tomadas, com destaque para as seguintes:

### 3.5.1. Medição das temperaturas dos mancais

Os responsáveis pelo monitoramento das temperaturas dos mancais realizam, de maneira rotineira, a conferência das temperaturas nas diversas condições de operação

da embarcação, verificando se as recomendações dos fornecedores ou das normas pertinentes (AMERICAN BUREAU OF SHIPPING, 2019), estão sendo respeitadas. Destaca-se que, maior atenção se faz necessária quando o navio estiver submetido a grandes guinadas executadas à altas velocidades. Caso as temperaturas venham a ultrapassar os valores especificados, uma ação de mitigação de eventuais problemas deve ser efetuada, uma vez que trata-se de um sintoma costumeiro de desalinhamento da linha de eixo (FARIAS, DOS REIS, *et al.*, 2021).

### 3.5.2. Análise de vibração

Assim como os demais equipamentos rotativos ou alternativos, a LE também deve passar, de tempos em tempos, pelo processo de análise de vibração. O não atendimento às normas pode impactar, tanto a confiabilidade do sistema de eixo como também o sistema de propulsão como um todo, bem como produzir vibrações prejudiciais ao bem estar da tripulação (DNV GL, 2017). Sendo assim, a manutenção do sistema sob níveis de vibração aceitáveis é de primordial importância, onde valores acima dos limites devem servir de alerta para a possível ocorrência de algum mal funcionamento (FARIAS, DOS REIS, *et al.*, 2021).

### 3.5.3. Medições das reações nos mancais

Tais medições são feitas mais comumente através de dois métodos (AMERICAN BUREAU OF SHIPPING, 2019, SNAME, 2007). Um se utiliza de macacos hidráulicos para a medição direta das pressões e, conseqüentemente, das reações nos mancais, sendo conhecido como *Jack-up Method* ou *Hydraulic Jack Method*. A Figura 4, esclarece melhor o processo de utilização dos macacos hidráulicos, onde observa-se diretamente do indicador, o valor da pressão sentida nas proximidades do mancal analisado.




Figura 4: Método do macaco hidráulico - (AMERICAN BUREAU OF SHIPPING, 2019)

O método do macaco hidráulico apresenta algumas vantagens consideráveis, entre as quais destacam-se o fato de ser um método que provê diretamente os valores das reações, e ainda, por tratar-se de equipamentos mais baratos e de fácil instalação. Em contrapartida, esse método têm uma relativa baixa acurácia se não forem utilizadas células de carga, uma vez que a carga medida pelo macaco acaba não sendo a carga experimentada bem ao centro do mancal, mas sim, em uma região próxima a este (AMERICAN BUREAU OF SHIPPING, 2019).

Já o segundo método, é realizado de forma indireta, através de medidores de deformação (*strain gauges*) (AMERICAN BUREAU OF SHIPPING, 2019, LEE, Jae ung, 2018), e, a partir destes, de maneira indireta, obtém-se as reações nos mancais, conforme o ilustrado pela Figura 5.

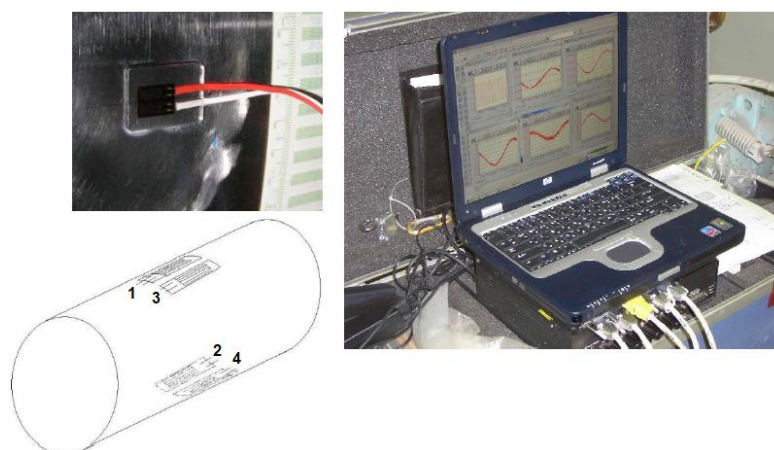


Figura 5: Medidores de deformação (AMERICAN BUREAU OF SHIPPING, 2019)

Destaca-se que tal método apresenta as vantagens de prover acesso a mancais em regiões da embarcação onde o método do macaco hidráulico não conseguiria ser

instalado, e ainda, os medidores de deformação são capazes de prover dados de carga tanto verticais quanto horizontais, podendo também, prover informações simultâneas em mais de um mancal. Algumas das desvantagens desse método consistem no relativo longo tempo para a correta instalação dos sensores e da necessidade de utilização de equipamentos sofisticados e relativamente caros (AMERICAN BUREAU OF SHIPPING, 2019).

Em resumo, cada método tem seus prós e contras, sendo ambos de grande valor na correta verificação dos valores do conjunto de recalques. Havendo alteração no conjunto inicial de recalques, pode-se, com o auxílio da Matriz dos Coeficientes de Influência (MCI), determinar se tal modificação resulta em uma LE desalinhada e, sendo esse o caso, tomar medidas corretivas para recuperar o estado de alinhamento inicial.

### 3.6. Regras de alinhamento do sistema de eixo

Os critérios de alinhamento seguidos neste estudo são os definidos em (SNAME, 2007), esta referência indica ainda alternativas em caso da falta de informações dos fornecedores, ou de arranjos do sistema de eixo mais complexos. Por exemplo, alguns valores variam de acordo com os tipos de materiais que compõem as buchas dos mancais e, com o tipo de fluido lubrificante que é utilizado. Isto posto, seguem-se as seis regras que devem ser atendidas para que se obtenha uma LE dita estaticamente alinhada:

- ✓ Regra 1 – O diferencial de carregamento entre os mancais da engrenagem redutora não deve ser excedido.

As reações dos mancais de ré e de vante da engrenagem redutora devem atender a critérios estabelecidos pelo seu fabricante. No entanto, se este valor não estiver acessível, a regra geral a ser obedecida é tal que o módulo da diferença das reações estáticas destes dois mancais deva ser menor que 25% da soma das duas reações destes mesmos mancais, conforme o apresentado pela Eq. (3.1).

$$|Rv - Rr| < 0,25 \times (Rv + Rr) \quad (3.1)$$

onde:

Rv – Reação do mancal de vante da engrenagem redutora; e

Rr – Reação do mancal de ré da engrenagem redutora.



- ✓ Regra 2 – Nenhum mancal de sustentação deve estar carregado acima de sua pressão máxima admissível.

Nenhum mancal de sustentação do sistema deve estar carregado acima do seu limite máximo. Esse limite é, geralmente, definido em termos de pressão e fornecido pelo fabricante. Outrossim, o limite máximo admissível para um mancal específico é definido pela razão da reação a qual o mancal está sendo exposto pela sua área projetada, resultando assim, em uma pressão máxima admissível.

Tem-se ainda, os seguintes valores de pressões admissíveis (SNAME, 2007), para o caso da falta dos dados dos fabricantes, são dados por:

- Mancais Intermediários:
  - Mancais lubrificados por disco: 500 kPa; e
  - Mancais lubrificados por anel: 350 kPa.
- Mancais do Tubo Telescópico:
  - Lubrificados com óleo e com a bucha de material sintético: 600 kPa;
  - Lubrificados com óleo e com a bucha de metal branco (*Babbitt*): 800 kPa;
  - Lubrificados com água e com a bucha de material sintético: 500 kPa; e
  - Lubrificados com água e com a bucha de borracha ou madeira: 300 kPa.

- ✓ Regra 3 – Nenhum mancal de sustentação deve ser carregado abaixo da sua carga mínima.

A tarefa de determinar a carga mínima que um mancal é capaz de sustentar, sem os dados fornecidos pelo fabricante, pode ser um tanto quanto arbitrária (SNAME, 2007), sendo assim, foi considerado nessa dissertação que nenhum mancal deveria estar submetido a cargas nulas ou negativas. Ou seja, caso a carga sofrida por um determinado mancal seja positiva, considerar-se-á que a Regra 3 está sendo atendida.

- ✓ Regra 4 – As tensões máximas de flexão, normal e de cisalhamento admissíveis no eixo não devem ser excedidas.

Trata-se de um critério de alinhamento de alta prioridade, uma vez que essas tensões suportadas pelo eixo são diretamente afetadas pelo seu alinhamento. Tais tensões, se excedidas, podem causar até uma eventual perda do sistema propulsivo. Então, para conferir se os valores das tensões respeitam os valores admissíveis, foram considerados os vãos da LE, suas propriedades mecânicas e suas tensões e reações obtidas do *software* de elementos finitos utilizado na análise estática. Só então, pode-

se calcular se as tensões experimentadas estão dentro dos limites obtidos a partir da tensão de escoamento do material da LE e do coeficiente de segurança aplicado.

✓ Regra 5 – Inclinação do Mancal de Ré do TT.

O mancal do eixo propulsor, o de ré do TT no cenário estudado, tem como função principal suportar o peso do propulsor, o peso da LE, e ainda neutralizar as forças hidrodinâmicas induzidas pelo hélice (SNAME, 2007). Logo, a inclinação deste mancal é crítica, devendo estar alinhada com o eixo propulsor para que a carga seja distribuída na maior área possível da bucha do mancal. Desta forma, admite-se, como regra geral, uma inclinação máxima, para mancais lubrificados com óleo, de 0,003 rad (0,17 graus).

✓ Regra 6 – Inclinação do Mancal de Vante do TT.

Assim como o apresentado para o mancal de ré do TT, o mancal de vante do TT, caso exista, também deve atender a inclinação máxima de 0,003 rad (0,17 graus). Uma vez que há uma grande relação entre os recalques de ambos os mancais do TT e as reações que estes sofrem, há necessidade de encontrar um equilíbrio entre a posição vertical destes mancais. Diante do exposto, uma das soluções pode ser uma leve inclinação em um ou em ambos para uma melhor acomodação do eixo (SNAME, 2007).

Em suma, com o auxílio da MCI, detalhadamente explicada na seção 4.1, tornou-se possível a obtenção das reações nos mancais para um determinado conjunto de recalques e, a partir da área de contato das suas buchas, foram determinadas as pressões atuantes de acordo com a condição estudada. Similarmente, valores de momentos, tensões e deflexões, necessárias para a verificação das demais regras citadas, foram obtidos dos resultados da representação da LE em elementos finitos, sendo esta etapa também apresentada em detalhes na seção 5.2.

Ao término da apresentação das etapas de revisão bibliográfica, capítulo 2, e dos fundamentos teóricos, capítulo 3, pôde-se criar uma metodologia de trabalho a qual é apresentada no capítulo a seguir.

## 4. Metodologia

As primeiras etapas que permitiram o desenvolvimento da metodologia desta dissertação foram a seleção da LE e sua posterior representação utilizando o método de elementos finitos, detalhadas nas seções 5.1 e 5.2. Em seguida, determinaram-se os coeficientes de influência, 4.1, e, a partir das regras apresentadas na seção 3.6 (SNAME, 2007), classificaram-se as variáveis preditoras, tornando possível efetuar a criação dos bancos de dados que serviram de base para os modelos de ML desenvolvidos, 5.3.

Procurando-se alcançar o objetivo principal desta dissertação, definido ainda no capítulo 1, o próximo passo consistiu na confecção de modelos de ML, buscando-se uma precisão mínima de 95,00%. A missão destes modelos consiste em acelerar a definição sobre se um determinado conjunto de recalques deve ou não ser aplicado para o alinhamento do sistema de eixo analisado e, desta maneira, diminuir o tempo gasto associado ao método de alinhamento através de tentativa e erro, comumente utilizado nos estaleiros de todo o mundo, onde chega-se a gastar até a dias para completar tal tarefa (FARIAS, DOS REIS, *et al.*, 2021).

Observa-se, portanto, que o trabalho desenvolvido congregou conceitos de análise estrutural com os de ML, uma vez que se analisou desde a representação do sistema de eixo em elementos finitos, passando pela elaboração da matriz dos coeficientes de influência, até chegar às etapas de refinamento dos hiperparâmetros dos algoritmos de ML.

Nesse sentido, a Figura 6 resume a metodologia que foi desenvolvida e empregada durante este trabalho, no formato de um fluxograma. Ela percorre desde a seleção da LE analisada, até chegar-se na avaliação e seleção do modelo de ML que retornou os melhores resultados de predição.

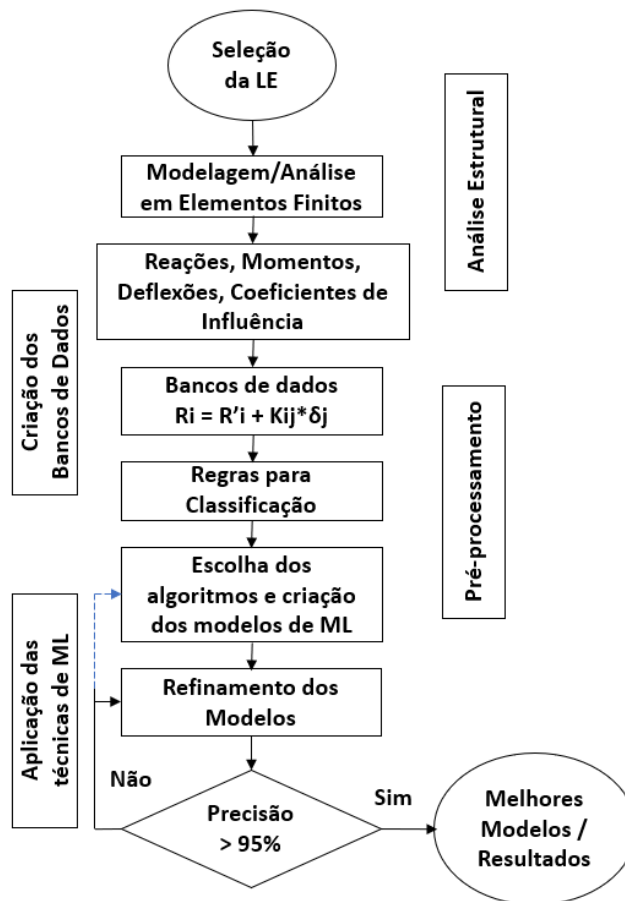


Figura 6: Fluxograma da Metodologia empregada

#### 4.1. Matriz dos coeficientes de influência (MCI)

A MCI tabula a relação entre as reações relativas dos mancais, caso uma mudança de deslocamento unitária, no caso estudado, de um milímetro, em um determinado mancal ocorra (AMERICAN BUREAU OF SHIPPING, 2019, SNAME, 2007).

Deste modo, a determinação da MCI foi de fundamental importância para o prosseguimento deste trabalho, uma vez que foi a partir dela, que tornou-se possível simular variadas condições de alinhamento para diferentes conjuntos de *offsets*. Estes conjuntos foram utilizados como banco de dados que alimentaram os modelos de ML na previsão dos resultados, objetivo principal deste trabalho.

Para a determinação da MCI, mais uma vez fez-se necessário executar o *software MetRig* em algumas condições específicas. A primeira delas foi realizada considerando-se os mancais concêntricos, e apenas o peso próprio da LE. Ou seja, os pesos da engrenagem redutora e do propulsor foram desconsiderados nessa simulação. Em

seguida, com deslocamentos unitários de 1 milímetro para cada um dos 7 mancais, desta vez sem levar em consideração o peso da própria LE, obtiveram-se as reações em cada um destes cenários, permitindo a organização destas reações, em N/mm, no formato de uma matriz, Tabela 1.

Ressalta-se ainda, que para a verificação de atendimento dos critérios, fez-se necessário executar o *software* todas as vezes em que variavam-se o conjunto de recalques, o que acabou por limitar a quantidade de amostras que compuseram os bancos de dados dos modelos de ML. Ainda assim, a quantidade de amostras foi considerada satisfatória, haja visto os resultados dos modelos obtidos, capítulo 6.

Tabela 1: Matriz dos coeficientes de influência (valores em N/mm)

<b>Matriz dos Coeficientes de Influência</b>							
	M1	M2	M3	M4	M5	M6	M7
M1	1820	-5002	3729	-708	232	-134	63
M2	-5002	16367	-16317	6409	-2101	1213	-570
M3	3729	-16317	24137	-17482	8551	-4938	2319
M4	-708	6409	-17482	24028	-21765	17948	-8430
M5	232	-2101	8551	-21765	43010	-70381	42453
M6	-134	1213	-4938	17948	-70381	172739	-116446
M7	63	-570	2319	-8430	42453	-116446	80611

As MCI são matrizes simétricas e quadradas, de ordem  $n \times n$ , onde  $n$  é o número de mancais da LE. Seus valores são dados, geralmente, em N/mm. Ademais, destaque é dado ao fato de que o cálculo dos coeficientes de influência só depende da geometria da LE e da sua rigidez, conforme o exposto em (SNAME, 2007). Os valores apresentados já são os da LE abordado no estudo de caso apresentado no capítulo 5. Por fim, vale lembrar que as somas dos valores de uma determinada linha ou coluna é igual a zero.

Desta forma, de posse da MCI e com a Eq. (4.1) - equação da influência - apresentada abaixo, tornou-se possível o cálculo das reações nos mancais para um novo conjunto de recalques:

$$R_i = R'_i + K_{ij} \cdot \delta_j \quad (4.1)$$

onde:

$R_i$  – vetor das novas reações experimentadas por cada um dos mancais  $i_1^n$ , para o novo conjunto de recalques  $\delta_j$ ;

$R'_i$  – vetor das reações de cada um dos mancais para a condição concentricamente alinhada (obtido previamente via elementos finitos);

$K_{ij}$  – coeficientes de influência (dados da MCI);

$\delta_j$  – novo conjunto (vetor) de recalques dos mancais.

Foi, portanto, a partir dos dados da matriz dos coeficientes de influência ( $K_{ij}$ ) que, com o novo vetor de recalques ( $\delta_j$ ) e com os valores das reações nos mancais concentricamente alinhados ( $R'_i$ ) tornou-se possível gerar os bancos de dados, com os novos valores de reações ( $R_i$ ) experimentados por cada mancal. Foram estes os coeficientes utilizados pelos modelos de ML que, através do processo de aprendizado supervisionado (*supervised learning*), foram testados, refinados e avaliados, quanto aos seus índices de precisão, na tarefa de classificação dos conjuntos de recalques.

Para condições distintas, tais como navio emerso ou imerso, quente ou frio, a única alteração para a obtenção dos novos valores das reações se dará devido a mudança nos valores de  $R'_i$ . Uma vez que seu valor varia para cada uma destas condições, seja pela modificação do peso do propulsor, quando passando de emerso para imerso, seja pelas considerações das dilatações térmicas em determinados mancais, quando se avalia o navio na condição quente, e assim por diante.

Finalmente, ressalta-se que não foram levadas em consideração as diferentes deflexões do casco, nestes diferentes cenários de operação citados acima. Trata-se, portanto, de uma simplificação a ser superada, com representações em elementos finitos mais refinadas da LE, ao menos da região da popa e PM do navio, caso resolva-se aplicar a técnica aqui desenvolvida, em uma embarcação em operação.

## 4.2. Regras de classificação da variável alvo

Entenda-se por variável alvo como sendo aquela a qual o modelo de inteligência artificial e, nesse caso, mais especificamente, o seu ramo de estudo de aprendizagem de máquinas, será capaz de prever (problemas de classificação) ou estimar (problemas de regressão). Isto posto, as amostras foram divididas em classes (*labels*) e a partir destas, os modelos irão prever a qual destas classificações possíveis um novo conjunto de recortes se enquadrará. Configurando assim um estudo de aprendizado supervisionado.

As regras de classificação de cada uma das quatro classes estabelecidas para a variável alvo (*target feature*) são apresentadas a seguir assim como a forma utilizada para a definição das mesmas:

### ✓ **Ótimo**

Classificação dada aos conjuntos que, após a implementação dos seus valores no *software* de elementos finitos e, obtidas todas as informações necessárias, entre elas reações nos mancais, deflexões da linha de eixo, tensões, e etc., respeitam a todos os seis critérios elencados na seção 3.6, resultando em uma LE corretamente alinhada.

### ✓ **Bom**

Aquele onde um dos seis critérios não foi atendido. Ou seja, o conjunto estava perto de atender à todas as regras, todavia faltou atender alguma delas e, portanto, o sistema se encontraria desalinhado. Sendo assim, espera-se que pequenos ajustes sejam capazes de chegar-se à configuração alinhada.

### ✓ **Regular**

Aquele onde quaisquer duas regras não fossem satisfeitas. Ou seja, este conjunto já requer mais correções do que os conjuntos bons e menos que os ruins, classificados conforme abaixo.

### ✓ **Ruim**

Aqueles conjuntos que não atendem mais de duas regras, ou seja, os recortes deste conjunto retornam valores bem aquém daqueles esperados para uma LE alinhada.

Desta forma, são essas as quatro classes que foram utilizadas como variáveis alvo (*target features*) nos modelos de aprendizado de máquina. A contribuição principal destes modelos foi, portanto, aproveitar os conjuntos classificados como “ótimos” e descartar os demais, economizando tempo e otimizando o processo de alinhamento dos sistemas de linhas de eixo principais.

Optou-se por quatro classes ao invés de duas, “alinhado” e “desalinhado”, por exemplo, uma vez que haveria um desbalanceamento de classes bem significativo, onde conjuntos classificados como “desalinhados” estariam em um número consideravelmente maior. Essa diferença do quantitativo de dados poderia ser um problema ainda maior quando da aplicação dos modelos de ML, como o abordado na subseção 2.2.2, quando comparando-se com o observado ao se considerar as quatro classes supracitadas. Ademais, um conjunto classificado como “bom” não causaria os mesmos prejuízos à LE que um classificado como “ruim”, sendo este último consideravelmente mais preocupante, o que corrobora para a escolha das quatro classes em detrimento à configuração onde só duas classes se fariam presentes.



## 5. Estudo de Caso

Seguindo os conceitos apresentados no capítulo 4, deu-se, como primeiro passo, a seleção da LE que foi estudada, com sua posterior representação como um pórtico plano em um programa (*software*) de elementos finitos.

Este *software*, o *MetRig*, foi desenvolvido pela equipe do Laboratório de Ensaio Dinâmicos e Análise de Vibrações (LEDAV). Ele utiliza o *Método da Rigidez* (também conhecido como *Método do Deslocamento*) representando a estrutura da LE como elementos discretos que são submetidos a determinados tipos de carregamentos, tais como o seu peso próprio, do propulsor, e da engrenagem redutora. Além disso, consideram-se ainda as forças de empuxos dependendo do fluido no qual a LE está imersa. E, por fim, submetem-se tais elementos às restrições em seus pontos de apoio (mancais). Tais restrições devem variar de acordo com o propósito de cada mancal. Desta forma, aplicaram-se restrições de 1º e 2º gêneros conforme o exposto em detalhes na seção 5.2.

Portanto, foi a partir desta representação que se tornou possível, utilizando-se o conceito de matriz dos coeficientes de influência, seção 4.1, possível a obtenção dos dados que viabilizaram analisar se a LE, com um conjunto de recalques selecionado, na condição desejada, estaria alinhada ou se ajustes se fariam necessários. Valores das reações em cada um dos mancais, esforços cortantes e momentos fletores na linha de eixo, além das deflexões desta nos mancais, fazem parte das informações que foram obtidas neste *software* e que possibilitaram afirmar se o sistema está ou não atendendo às regras de alinhamento vigentes (SNAME, 2007).

### 5.1. Linha de eixo analisada

A linha de eixo que foi analisada é pertencente a uma embarcação *AHTS* (*Anchor Handling and Tug Supply*), não inclinada em relação à quilha, sendo seu material o aço ASTM1045, cujas propriedades mecânicas tais como módulos de elasticidade longitudinal, transversal, coeficiente de Poisson, densidade e tensão limite de escoamento, foram descritas na Tabela 2. Ademais, o comprimento da LE, pesos da engrenagem redutora e do propulsor, densidades do óleo lubrificante e da água do mar,

fluidos aos quais algumas das seções do eixo, além do próprio propulsor, estão imersos, também são apresentados na Tabela 2.

Tabela 2: Resumo dos dados da linha de eixo analisada

L (m)	38,824	$\rho_{aço}$ (kg/m <sup>3</sup> )	7.870
Material	Aço ASTM1045	Peso Propulsor (N)	124.550 no ar
E (GPa)	210		108.283 na água
$\nu$	0,3	Peso Redutora (N)	102.754
G (GPa)	80,77	$\rho_{óleo}$ (kg/m <sup>3</sup> )	800
$\sigma_e$ (MPa)	450	$\rho_{as}$ (kg/m <sup>3</sup> )	1.026

A escolha por essa classe de navios residiu no alto número de problemas de alinhamento que vêm acometendo tais embarcações.

Já os detalhes da seção transversal do *AHTS* analisado, das seções da LE, dos mancais, e o desenho técnico com os valores das seções da LE são apresentados nas Figura 7 e Figura 8, respectivamente.




Figura 7: Navio *AHTS* analisado no estudo de caso




Figura 8: Linha de Eixo estudada

Ademais, a LE selecionada é composta por 7 mancais, vide Figura 8, sendo estes nomeados, de ré para vante, da seguinte forma:

- ✓ Mancal 1: Mancal de Ré do TT;
- ✓ Mancal 2: Mancal de Vante do TT;
- ✓ Mancal 3: Mancal Intermediário 1;
- ✓ Mancal 4: Mancal Intermediário 2;
- ✓ Mancal 5: Mancal Intermediário 3;
- ✓ Mancal 6: Mancal de Ré da Caixa Redutora;
- ✓ Mancal 7: Mancal de Vante da Caixa Redutora.

Outrossim, destaca-se que os mancais mais a ré, 1 e 2, são mancais estruturais e, sendo assim, nos cálculos para determinação das novas reações, seus recalques foram sempre considerados como zero. Desta forma, eles foram considerados como estando na condição de alinhamento original, estando, portanto, alinhados concentricamente.

Face ao exposto, com a configuração da linha de eixo definida, pôde-se então representá-la no *software* de elementos finitos, para, a partir deste, obterem-se informações que indicam se o alinhamento estático foi atendido ou não, isto é, se as forças, momentos, tensões e deflexões atenderam aos critérios de alinhamento estipulados e que foram apresentados em detalhe na seção 3.6.

Ressalta-se, portanto, que o alinhamento estático se trata de um pré-requisito para a obtenção de um comportamento dinâmico aceitável do sistema da linha de eixo (ŠVERKO, 2005), de tal forma que os próximos passos foram dados na direção de alcançar tal condição.

## 5.2. Modelagem da linha de eixo

Para a modelagem e posterior análise estrutural da LE selecionada, utilizou-se o *software* de elementos finitos *MetRig* que, conforme anteriormente mencionado, aplica conceitos do *Método da Rigidez* para analisar o comportamento de vigas. No caso estudado, a representação da LE se deu através de um pórtico plano, com as devidas restrições sendo aplicadas de acordo com as funções de cada um de seus mancais.

A modelagem foi realizada criando-se um nó no início de cada seção de área constante e, aquelas de maiores comprimentos tiveram ainda nós intermediários adicionados. Além do mais, um nó foi adicionado na posição correspondente à metade do comprimento da bucha de cada um dos mancais, por se tratar da posição onde espera-se que os mancais devam experimentar a maior parte das reações, com exceção do mancal de ré do TT onde o nó foi adicionado a 1/3 do comprimento da bucha a partir de sua extremidade de ré, como forma de ser mais fiel às reações experimentadas por esse mancal em específico, sendo este muito influenciado pela posição e peso do propulsor.

Outrossim, inseriu-se ainda um nó em cada selo e um nó em cada posição onde há uma carga aplicada, no caso, no ponto onde o propulsor se localiza, ponto A, e também a engrenagem redutora, ponto B, tal qual o ilustrado pela Figura 8.

Resumindo, a LE está agora modelada como uma sequência de elementos finitos, com 50 nós e 49 elementos, tal qual o apresentado pela Figura 9. Nesta ilustração, apresentam-se os nós iniciais (1), os respectivos ao posicionamento dos sete mancais e o último (50), como forma de obter-se uma melhor visualização.




Figura 9: Nós e Elementos da LE – Interface *MetRig*

A LE foi dividida em 16 seções com propriedades estruturais diferentes, onde cada uma delas possui um diâmetro diferente. Por fim, ainda criaram-se 3 grupos distintos, onde cada um deles corresponde ao fluido em que esta parte está imersa. Portanto, um grupo foi designado para o trecho que fica exposto a água do mar, parte externa ao casco, outro para exposição ao óleo lubrificante, região do tubo telescópico e, por fim, o outro que fica protegido dentro do navio, este último exposto ao ar.

Representaram-se ainda os sete mancais, dos quais os seis primeiros foram projetados como apoios de 1º gênero, isto é, com restrição de deslocamento em X (nós de números 6, 12, 20, 26, 35 e 45, vide Figura 9). Já o mancal 7, nó 49, foi projetado como um apoio de 2º gênero, isto é, com restrições de rotação no eixo Z e de deslocamento no eixo X.

A partir desta representação, obtiveram-se as reações e momentos experimentados pela LE e seus mancais, Figura 10, em diferentes condições. Logo, tornou-se possível, por exemplo, estudar cenários em que o navio está emerso (em dique seco), ou flutuando. Foi possível, ainda, analisarem-se cenários como se, o navio estivesse imerso com máquinas paradas, navio “frio”, sem efeitos térmicos provenientes das altas temperaturas do maquinário. E, por fim, com o navio em operação, navio “quente”, levando-se em consideração os efeitos da dilatação térmica nos mancais mais próximos às fontes de temperatura mais altas (mancais 6 e 7). Tais condições são detalhadas na seção 5.4.




Figura 10: Saída gráfica dos resultados obtidos do *software MetRig*

Isto posto, torna-se possível confrontar, para determinadas condições desejadas, se os resultados obtidos (reações, tensões, inclinações, momentos, esforços cortantes, etc.) através do modelo de elementos finitos atendem às regras estipuladas pelas normas que regem o correto alinhamento de eixos de propulsão principal (SNAME, 2007), seção 3.6.

### 5.3. Bancos de Dados

A criação do banco de dados passou principalmente pela representação em elementos finitos e pela análise estrutural da LE. Desta maneira, tornou-se possível a obtenção das reações com os mancais concentricamente alinhados e também determinar-se a sua matriz dos coeficientes de influência.

De posse da MCI e das reações de cada mancal, quando concentricamente alinhados, foi possível determinarem-se os valores das reações, bem como das pressões, ao dividirem-se suas reações pelas respectivas áreas projetadas, as quais cada um deles pode estar submetido para quaisquer conjuntos de recalques que se queira testar, utilizando-se a Eq. (4.1).

Destaca-se que os mancais do TT, M1 e M2, são mancais estruturais e, portanto, possuem sempre a mesma posição vertical ( $\delta_1 = \delta_2 = 0$ ) não havendo possibilidade de ajustes dos seus recalques, uma vez que, na prática, trata-se de uma região de difícil acesso e trabalho.

No entanto, outras medidas são necessárias para obter-se uma configuração que satisfaça aos critérios de alinhamento estático (SNAME, 2007). São elas as deflexões, as inclinações, os esforços cortantes e os momentos fletores ao longo do eixo, tal qual o exposto em detalhes na seção 3.6. Estas devem ser calculadas através da análise estrutural e para isso, mais uma vez, o programa *MetRig* foi utilizado. Diferentemente das reações, os valores citados acima só puderam ser obtidos executando-se o programa para cada conjunto de recalques, um por um. Logo, essa etapa de levantamento dos bancos de dados foi extremamente trabalhosa e, um limitador, caso um eventual aumento na quantidade de amostras se fizesse necessário.

O vetor contendo os novos valores de recalques,  $\delta_j$ , devem, portanto, ser tais que abranjam uma considerável gama de possíveis variações de recalques a que os mancais possam estar submetidos. Segundo (AMERICAN BUREAU OF SHIPPING,

2019, SNAME, 2007), essas variações se devem a três fatores principais, sendo eles, as deflexões do casco, o desgaste dos mancais e ainda a dilatação/contração térmica.

Desta forma, os recalques que compuseram este trabalho foram criados, de maneira aleatória, variando-se os valores dos mancais 3 a 7, de -20 mm a + 25 mm, valores estes considerados condizentes com o conjunto LE-navio analisado. A título de comparação, os valores aqui considerados foram maiores que os apontados no estudo de (SEO, JEONG, *et al.*, 2020), que analisou um navio VLCC (*Very Large Crude Carrier*), sendo que tal classe de navios tende a ter cascos ainda mais flexíveis do que os navios *AHTS* e, portanto, espera-se que o conjunto abrangido seja suficiente para eventuais correções na linha estudada.

Outro fator observado consistiu do fato de que ao se gerar aleatoriamente os valores dos recalques, principalmente na grande faixa estudada, ocorreu uma grande superioridade de resultados classificados como “ruins”, sendo os resultados classificados como “ótimos” uma minoria significativa. Desta maneira, tal desbalanceamento foi superado através da aplicação das técnicas de super e subamostragem, apresentadas em detalhes na subseção 2.2.2.

Em resumo, levando-se todo o exposto em consideração, dadas as restrições da necessidade de se executar o programa toda vez que se alteravam os recalques, bem como as disparidades dos quantitativos de cada classe, decidiu-se estudar a priori três diferentes bancos de dados apresentados em detalhes a seguir.

### 5.3.1. Banco de dados 1 – 800 amostras balanceadas

Devido ao citado desbalanceamento dos dados, procedeu-se a implementação de técnicas de subamostragem (exclusão aleatória) das amostras classificadas como “ruins” e “regulares” e de superamostragem (*SMOTE*) dentre as classificadas como “ótimos” e “bons” na busca por um banco de dados equilibrado, ambas as técnicas detalhadas na subseção 2.2.2.

Ao término de ambos os processos de super e subamostragem, chegou-se a um banco de dados totalmente equilibrado, com cada uma das quatro classes contabilizando 200 amostras.

Em resumo, todos esses processos e técnicas se deram em virtude de buscar-se desde a etapa de pré-processamento, modelos robustos, com baixo viés, mais

generalistas e, evitando-se que problemas de sobreajuste (*overfitting*) prejudicassem os resultados obtidos.

Outra forma de amenizar os bancos de dados desbalanceados consiste na correta escolha da métrica de avaliação a ser levada em consideração. Tal abordagem foi também implementada e sua explicação apresentada em detalhes na subseção 2.2.1

### 5.3.2. Banco de dados 2 – 1600 amostras balanceadas

De forma análoga a explicada acima, vários conjuntos de recalques foram executados, separando-se os valores “ótimos” e “bons”, para que, ao se atingir 400 amostras de cada classe, se completasse o banco 2, totalizando 1600 amostras perfeitamente balanceadas (400 amostras de cada classe). Portanto, o banco 2 tem exatamente o dobro das amostras do banco 1.

Um acréscimo no número de amostras, tende a produzir melhores resultados, uma vez que a “máquina” (modelo) consegue absorver melhor as influências das variáveis preditoras na variável alvo (*target feature*). Foi usando-se esta prerrogativa que se definiram os dados do banco 2. Sendo assim, espera-se que os modelos tenham melhor desempenho quando utilizando-se este banco em comparação com o primeiro banco.

### 5.3.3. Banco de dados 3 – 1678 amostras desbalanceadas

Já para o terceiro banco de dados, foi permitido o desbalanceamento das amostras, justamente para, ao se compararem os desempenhos dos modelos de ML, poder-se verificar se houve impacto das técnicas de super e subamostragem nos resultados obtidos. Dessa forma, o banco 3, tem 200 conjuntos de amostras classificados como “ótimos”, 200 como “bons”, 278 como “regulares” e 1000 deles sendo da classe “ruins”.

Tais bancos de dados foram então testados em três condições (vide seção 5.4) sendo elas condições de navio docado, flutuando a frio (máquinas paradas) e flutuando a quente (máquinas ligadas, considerando-se o efeito da dilatação térmica, vide Tabela 3).

Observa-se uma ligeira modificação nos valores de amostras passados acima, quando se varia o tipo de condição do navio. Tal fato se esclarece, observando-se a Eq.



(4.1), onde os valores das novas reações dependem das reações concentricamente alinhadas,  $R'_i$ , e este valor se modifica quando da alteração da condição do navio. Ou seja, para o mesmo conjunto de recalques utilizado na condição de navio docado, classificado como “ótimo”, ele pode receber uma outra classificação quando na condição de navio frio, por exemplo. Desta forma, ao final da seção 5.4, apresenta-se um resumo com o quantitativo de cada classe, em cada banco de dados, e em cada uma das três condições.

## 5.4. Condições analisadas

Outra etapa estabelecida pelas referências (AMERICAN BUREAU OF SHIPPING, 2019, SNAME, 2007), e que deve ser levada em consideração no processo de alinhamento do sistema de eixo principal, trata-se da análise do alinhamento em diferentes condições, uma vez que o navio em sua vida útil acaba experimentando diferentes cenários de operação e nem sempre a sua LE estará alinhada em cada uma delas. Desta maneira, este estudo analisou três diferentes condições de operação para a embarcação, quais sejam, *navio docado*, *navio frio*, e *navio quente*. Os detalhes de cada tipo de condição são apresentados a seguir.

### 5.4.1. Condição 1 - navio docado

Nesta condição, considera-se toda a LE, bem como o propulsor, emersos. Ou seja, não se considera o empuxo da água do mar atuando no propulsor, nem na LE externa ao casco, nem tampouco o empuxo do óleo lubrificante atuando na linha que passa por dentro do tubo telescópico. Tal medida é feita no *software MetRig*, separando-se seções da LE em grupos, conforme o apresentado em 5.2. Neste caso, toda a linha de eixo foi, portanto, considerada como sendo parte do grupo 1, onde não há empuxo de óleo nem da água do mar.

Outra característica desta condição, é que o peso do propulsor considerado nessa simulação foi, conforme o exposto pela Tabela 2, de 124.550,0 N. Já o peso da engrenagem redutora, que fica sempre emersa, dentro da praça de máquinas do navio, foi considerado, nas três condições, igual a 102.754,0 N.

#### 5.4.2. Condição 2 - navio frio

A segunda condição analisada, foi a de *navio frio*, onde considera-se o navio flutuando no seu calado de projeto. Para tanto considerou-se a água salgada ( $\rho_{as} = 1.026 \text{ Kg/m}^3$ ) atuando no casco e provendo empuxo para a seção da LE externa ao casco, bem como para o propulsor. Adicionalmente, considerou-se o TT já sob o efeito do seu lubrificante ( $\rho_{\text{óleo}} = 800 \text{ Kg/m}^3$ ). Logo, nesta condição o peso do propulsor variou devido ao empuxo da água salgada, tendo seu valor igual a 108.283,0 N, ficando a LE, agora, dividida em três grupos, sendo o primeiro grupo, de vante para ré (a parte da LE emersa e localizada dentro da PM), o segundo a parte imersa em óleo lubrificante (dentro do TT) e, por fim, o terceiro, sendo a parte externa (imersa em água salgada).

#### 5.4.3. Condição 3 - navio quente

Enfim, a terceira e última condição estudada, considerou que o Motor de Combustão Principal (MCP) estava em operação, impactando em temperaturas elevadas e, por conseguinte, com uma dilatação de 0,046 mm nos mancais de ré e de vante da engrenagem redutora aplicada aos conjuntos de recalques analisados. Ademais, os valores de peso do propulsor e os três grupos de propriedades de materiais foram os mesmos da condição 2.

Em suma, a Tabela 3 apresenta todas as condições e bancos de dados analisados, bem como as diferenças das quantidades de amostras em cada classe. Conforme o explicado anteriormente na subseção 5.3.3, pode-se observar nesta tabela, as ligeiras alterações nas quantidades de classes em cada uma das condições analisadas, em virtude dos valores das reações concêntricas ( $R'_i$ ) que variam de acordo com as especificidades de cada condição.

Tabela 3: Resumo das análises testadas

Condição 1	Classes				Amostras Totais	
	Bancos	"Ótimo"	"Bom"	"Regular"		"Ruim"
1		200	200	200	200	800
2		400	400	400	400	1600
3		200	200	278	1000	1678

Condição 2	Classes				Amostras Totais	
	Bancos	"Ótimo"	"Bom"	"Regular"		"Ruim"
1		200	198	201	201	800
2		401	397	401	401	1600
3		200	198	280	1000	1678

Condição 3	Classes				Amostras Totais	
	Bancos	"Ótimo"	"Bom"	"Regular"		"Ruim"
1		192	195	211	202	800
2		384	398	411	407	1600
3		192	195	285	1006	1678

## 5.5. Variáveis preditoras e alvo

Criados os bancos de dados e definidas as condições analisadas, chegou-se a uma planilha com trinta e três colunas, das quais trinta e duas são as variáveis preditoras. Foram as informações contidas nessas variáveis as usadas para a predição das classes da variável alvo, denominada "Regra Final" pelos modelos. Outrossim, a Figura 11 apresenta as primeiras dez linhas de um dos bancos de dados testado.

ID	Offset M1 (mm)	Offset M2 (mm)	Offset M3 (mm)	Offset M4 (mm)	Offset M5 (mm)	Offset M6 (mm)	Offset M7 (mm)	R1(N)	R2(N)	R3(N)	R4(N)	R5(N)	R6(N)	R7(N)	P1 (kPa)	P2 (kPa)
1	0	0	0	0	1	1	1	2.63E+05	1.59E+05	1.06E+05	6.22E+04	8.20E+04	1.12E+05	7.81E+04	1.81E+02	1.75E+02
2	0	0	3	3	3	0	-1	2.72E+05	1.25E+05	1.43E+05	3.72E+04	1.14E+05	7.04E+04	9.99E+04	1.88E+02	1.37E+02
3	0	0	5	10	7	6	6	2.76E+05	1.32E+05	9.02E+04	1.32E+05	2.55E+04	1.26E+05	8.09E+04	1.90E+02	1.45E+02
4	0	0	0	-5	-5	-3	-2	2.65E+05	1.37E+05	1.55E+05	2.62E+04	8.69E+04	1.03E+05	8.95E+04	1.83E+02	1.50E+02
5	0	0	-3	-1	8	7	6	2.54E+05	1.91E+05	9.30E+04	3.82E+03	1.69E+05	7.04E+04	8.11E+04	1.75E+02	2.10E+02
6	0	0	-3	-2	5	2	0	2.54E+05	1.89E+05	9.56E+04	5.93E+03	1.59E+05	9.85E+04	6.07E+04	1.75E+02	2.07E+02
7	0	0	0	-5	-5	-3	-2	2.65E+05	1.37E+05	1.55E+05	2.62E+04	8.69E+04	1.03E+05	8.95E+04	1.83E+02	1.50E+02
8	0	0	-1	-1	-4	-3	-2	2.59E+05	1.76E+05	6.95E+04	1.18E+05	3.43E+04	1.09E+05	9.59E+04	1.79E+02	1.94E+02
9	0	0	1	8	7	-1	-4	2.62E+05	1.82E+05	4.00E+04	1.13E+05	1.03E+05	6.51E+04	9.75E+04	1.81E+02	2.00E+02
10	0	0	0	0	0.5	0.5	0.5	2.63E+05	1.60E+05	1.03E+05	6.83E+04	7.44E+04	1.19E+05	7.48E+04	1.81E+02	1.75E+02

P3 (kPa)	P4 (kPa)	P5 (kPa)	P6 (kPa)	P7 (kPa)	θ Ré (rad)	θ Vante (rad)	Cisalhamento Máx (MPa)	Flexão Máx (MPa)	Regra 1	Regra 2	Regra 3	Regra 4	Regra 5	Regra 6	Regra Final
2.65E+02	1.55E+02	2.05E+02	2.67E+02	1.86E+02	0.0002	6.5E-06	0.248648	13.7499	1	1	1	1	1	1	Ótimo
3.58E+02	9.30E+01	2.84E+02	1.68E+02	2.38E+02	3.2E-05	0.00033	0.270036	14.3511	1	1	1	1	1	1	Ótimo
2.25E+02	3.30E+02	6.37E+01	3.00E+02	1.93E+02	-1E-05	0.00043	0.277442	21.1386	1	1	1	1	1	1	Ótimo
3.87E+02	6.54E+01	2.17E+02	2.45E+02	2.13E+02	0.00016	9.1E-05	0.253119	19.3122	1	1	1	1	1	1	Ótimo
2.32E+02	9.55E+00	4.22E+02	1.68E+02	1.93E+02	0.00037	-0.0003	0.251759	29.1996	1	1	1	1	1	1	Ótimo
2.39E+02	1.48E+01	3.97E+02	2.35E+02	1.45E+02	0.00036	-0.0003	0.299244	28.9404	1	1	1	1	1	1	Ótimo
3.87E+02	6.54E+01	2.17E+02	2.45E+02	2.13E+02	0.00016	9.1E-05	0.253119	19.3122	1	1	1	1	1	1	Ótimo
1.74E+02	2.95E+02	8.56E+01	2.60E+02	2.29E+02	0.00027	-0.0001	0.237884	13.7499	1	1	1	1	1	1	Ótimo
9.98E+01	2.81E+02	2.57E+02	1.55E+02	2.32E+02	0.00021	-1E-05	0.249993	19.0922	1	1	1	1	1	1	Ótimo
2.58E+02	1.71E+02	1.86E+02	2.84E+02	1.78E+02	0.00021	3.8E-06	0.258303	13.7499	1	1	1	1	1	1	Ótimo

Figura 11: Variáveis Preditoras e Alvo ("Regra Final")

A variável “ID”, foi utilizada para organizar e ser o contador das amostras. Sendo assim, esta variável não possui nenhuma informação que ajude na correta classificação da variável alvo.

Já as variáveis “Offset M1 (mm)” e “Offset M2 (mm)”, conforme já explicado, são sempre 0, uma vez que os recalques destes mancais não variam por se tratar de mancais estruturais e por estarem concentricamente alinhados.

As seguintes cinco colunas, a partir de “Offset M3 (mm)” até “Offset M7 (mm)”, foram os recalques dos cinco mancais que foram aleatoriamente criados. Seus valores variaram de -20 a + 25 milímetros, como forma de atender às modificações dos posicionamentos verticais dos mancais, principalmente devido a eventuais deflexões do casco, expansões térmicas, ou ainda desgastes dos mancais, conforme o abordado nas publicações (AMERICAN BUREAU OF SHIPPING, 2019, SNAME, 2007), sendo o primeiro destes fatores o mais significativo conforme apresentado nos trabalhos de (LEE, Young-Jin, KIM, *et al.*, 2006, SEO, JEONG, *et al.*, 2020).

Portanto, de posse dos sete valores de recalques, e ainda com a aplicação da Eq. (4.1), obtiveram-se as sete variáveis – “R1 (N)” até “R7(N)” - uma para cada mancal, bem como as pressões experimentadas por estes – “P1 (kPa)” até “P7 (kPa)” – obtidas ao dividirem-se os valores das reações pelas respectivas áreas projetadas das buchas de cada um dos mancais, totalizando assim quatorze variáveis.

As seguintes quatro colunas, destacadas em cinza, “ $\theta$  Ré (rad)”, “ $\theta$  Vante (rad)”, “Cisalhamento Máx (MPa)” e “Flexão Máx (MPa)”, são obtidos através dos dados de saída (*outputs*) do programa de elementos finitos, e indicam, respectivamente, as inclinações do eixo nos mancais de ré e de vante do tubo telescópico, o cisalhamento máximo e o momento fletor máximo sentidos pelo eixo. São esses os valores que requerem que o programa seja rodado toda vez que se varia o conjunto de recalques e que limita a obtenção de bancos de dados com maiores quantidades de amostras.

Finalmente, com essas informações calculadas, foram atribuídos valores de 1 caso a regra em análise seja atendida, e de 0 em caso contrário. Efetuando-se tal procedimento para as 6 regras apresentadas na seção 3.6, torna-se possível classificar um determinado conjunto de recalques e assim galgar mais um passo, seguindo a metodologia adotada e apresentada no capítulo 4.

## 5.6. Pré-processamento e seleção de variáveis

Tal etapa consiste em uma das partes mais trabalhosas e importantes dos problemas de ML. Bons resultados são diretamente influenciados pelas ações tomadas nesta fase. A correta exclusão de variáveis que pouco ou nada agregam ao modelo, o preenchimento de dados faltantes (*missing data*), o processo de normalização das variáveis preditoras (quando necessário), entre outras, influenciam bastante em termos de resultados quando da avaliação dos resultados obtidos pelos modelos de ML, bem como reduzem significativamente o tempo para a execução dos mesmos.

Isto posto, decidiu-se pela exclusão das seguintes variáveis, sendo essas facilmente identificadas como não agregadoras de informações aos modelos de ML testados:

“Id” – por ser apenas um rótulo dos conjuntos de recalque, não acrescenta informação à base de dados;

“ $\theta$  Ré (rad)”, “ $\theta$  Vante (rad)”, “Flexão Máx (MPa)” e “Cisalhamento Máx (MPa)” – uma vez que estas variáveis já foram usadas na definição das colunas das Regras.

“Regra 1”, “Regra 2”, “Regra 3”, “Regra 4”, “Regra 5” e “Regra 6” – uma vez que estas colunas foram usadas para a definição da variável “Regra Final” e esta, sim, é a variável alvo (*target feature*). Ademais, seus valores de “0” ou “1”, pouco agregam aos modelos. Estas variáveis são as regras presentes na referência (SNAME, 2007), outrora apresentadas na seção 3.6, e que norteiam a análise de alinhamento estático de sistemas de eixos de propulsão principal.

“Offset M1 (mm)” e “Offset M2 (mm)” – pois tratam-se de mancais estruturais e como seus valores de recalques são sempre “0”, decidiu-se por excluí-las, uma vez que mantendo-as, nenhum ganho de informação seria adicionado ao classificador.

Eliminadas essas variáveis, optou-se por conferir as correlações das variáveis remanescentes, utilizando-se o conceito do *coeficiente de correlação de Pearson* (LANTZ, 2013). Uma vez que ainda pode-se haver altos valores de correlações, permitindo a eliminação de mais variáveis e ganhando assim desempenho computacional. Utilizando-se a ferramenta *Jupyter Notebook* - plataforma interativa para executar códigos na linguagem *Python* e valendo-se de bibliotecas já existentes para elaboração de gráficos, tais como *Matplotlib*, *Pyplot* e *Seaborn*, criou-se o *mapa de calor* (*heatmap*) das variáveis, uma ferramenta bem típica de análise de dados que permite

uma melhor compreensão de como uma determinada variável se correlaciona com as demais. Sendo assim, obteve-se a Figura 12 apresentada a seguir.

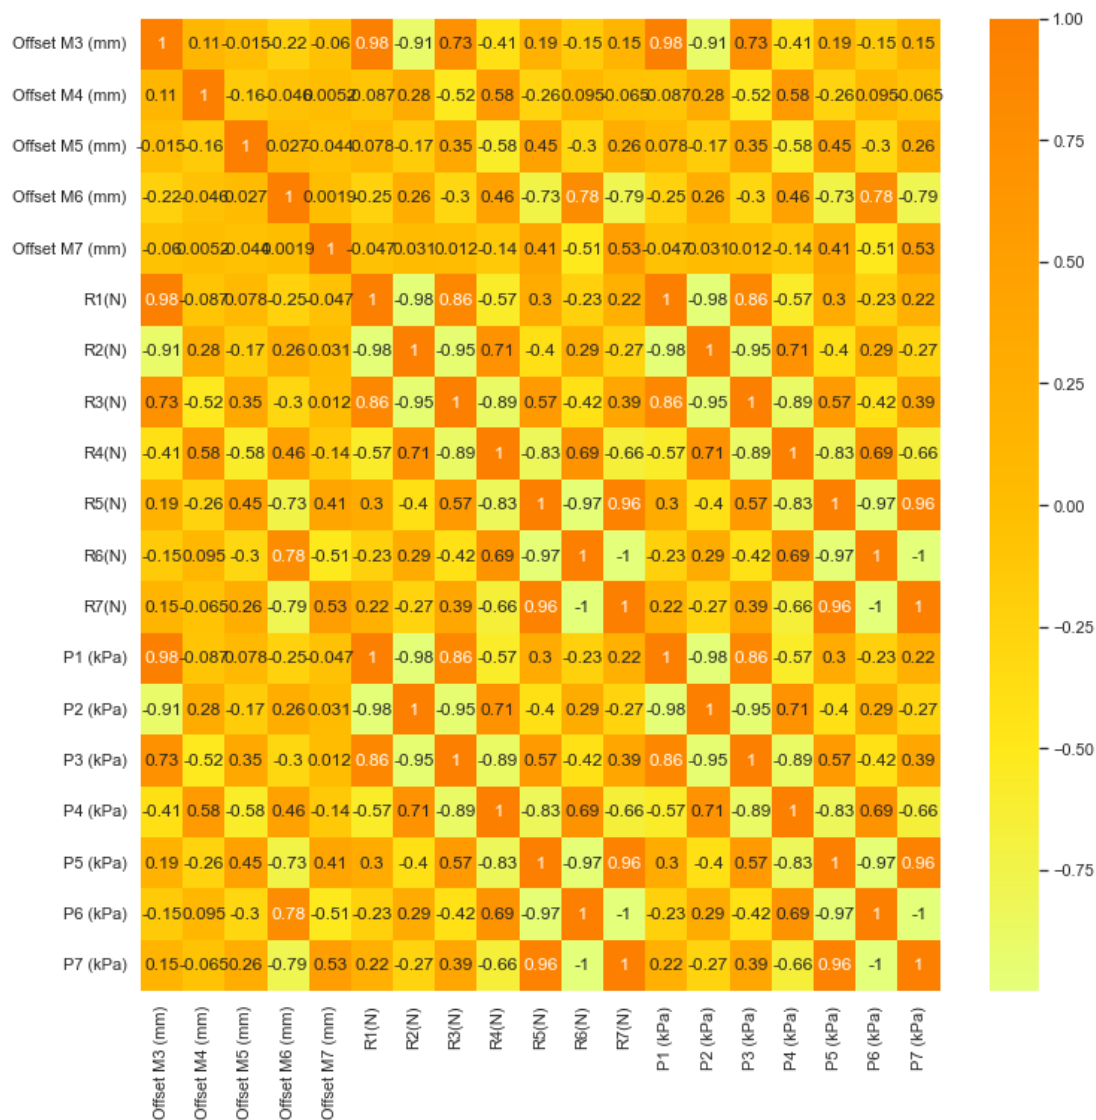


Figura 12: Mapa de Calor das variáveis predictoras após as primeiras exclusões.

Observa-se da Figura 12 que a correlação de uma determinada reação tem valores idênticos para reações e pressões de um mesmo mancal. Por exemplo, ao se observar a relação da reação do mancal 4 (“R4(N)”) e da pressão também do mancal 4 (“P4 (kPa)”) com o valor da reação 1 (“R1(N)”), nota-se que ambas têm a mesma correlação no valor de  $-0,57$ . Isto é observado em todo o mapa de calor para mancais “n” e reações e pressões “R<sub>n</sub>” e “P<sub>n</sub>”, respectivamente. Tal correlação ocorre devido às pressões obtidas através da divisão das reações pelas áreas projetadas das buchas dos mancais, que são valores constantes. Conclui-se, então, que mais variáveis podem ser excluídas sem prejuízos às análises que serão feitas pelos modelos mais à adiante. Optou-se, assim, pela exclusão das sete colunas das reações, de “R1(N)” a “R7(N)”.

Refazendo o *mapa de calor*, obtiveram-se as correlações, mas agora já sem as colunas das reações que foram excluídas, como pode ser visto na Figura 13.

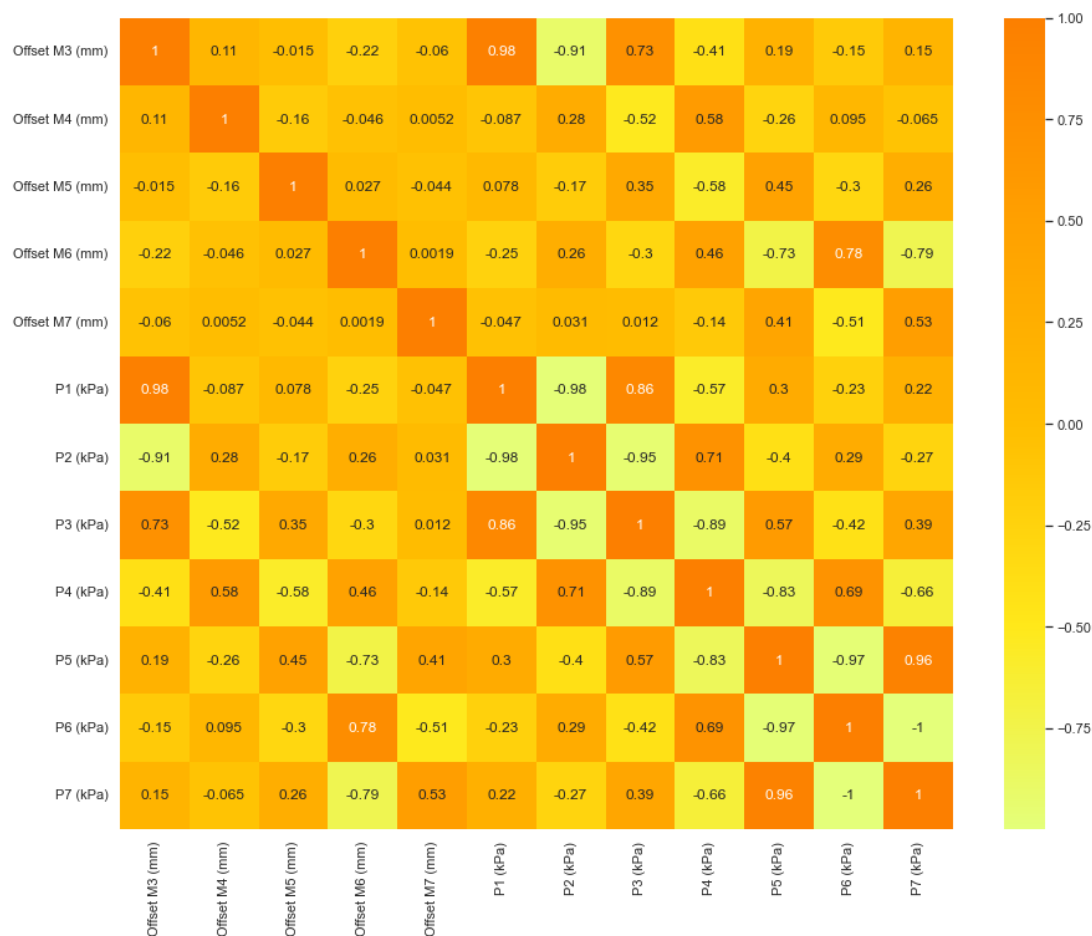


Figura 13: *Mapa de Calor* das variáveis predictoras remanescentes

Como previsto, o mapa de calor ainda traz a informação de uma alta correlação negativa nos valores das pressões entre mancais diretamente anteriores e posteriores. Ou seja, quaisquer ajustes positivos no recalque do mancal  $n$ , resultará em valores que diminuirão as reações e, por conseguinte, as pressões, experimentadas nos mancais  $n - 1$  e  $n + 1$ . Este cenário é condizente com o observado na MCI apresentada na seção 4.1.

Feitas as devidas análises e exclusões de variáveis, findou-se a etapa de pré-processamento, ressaltando que não houve *dados faltantes (missing data)* em nenhum dos bancos de dados analisados.

Portanto, os dados que foram testados pelos algoritmos foram compostos de doze variáveis predictoras, que são aquelas listadas na Figura 13, como discriminadas abaixo:

“Offset M3 (mm)”, “Offset M4 (mm)”, “Offset M5 (mm)”, “Offset M6 (mm)”, “Offset M7 (mm)”, “P1 (kPa)”, “P2 (kPa)”, “P3 (kPa)”, “P4 (kPa)”, “P5 (kPa)”, “P6 (kPa)” e “P7 (kPa)”.

Por fim, a variável alvo (*target*) que se deseja classificar pelos algoritmos com um elevado nível de *Precisão* é a variável “Regra Final”, sendo, portanto, essa a variável que classifica se os recalques adotados retornam valores de alinhamento estático “ótimos”, “bons”, “regulares” ou “ruins”.

Neste contexto, apresenta-se na Tabela 4, retirada do ambiente do *Jupyter Notebook* e convertida em formato de tabela, as variáveis restantes, após a etapa de pré-processamento, quando utilizadas no banco de dados 1, apresentando desta forma dez amostras, do total de oitocentas presentes no banco em questão.

Tabela 4: Banco de dados 1 pós-processado

	Offset M3 (mm)	Offset M4 (mm)	Offset M5 (mm)	Offset M6 (mm)	Offset M7 (mm)	P1 (KP a)	P2 (KP a)	P3 (KP a)	P4 (KP a)	P5 (KP a)	P6 (KP a)	P7 (KP a)	Regra Final
0	0	0	1	1	1	181,4	174,6	265,0	155,4	204,7	266,9	186,1	Ótimo
1	3	3	3	0	-1	187,9	137,3	358,4	93,0	284,3	167,8	238,1	Ótimo
2	5	10	7	6	6	190,1	145,1	225,3	329,9	63,7	300,2	192,9	Ótimo
3	0	-5	-5	-3	-2	183,1	149,9	387,2	65,4	217,0	245,3	213,2	Ótimo
4	-3	-1	8	7	6	174,9	210,0	232,3	9,5	422,4	167,7	193,3	Ótimo
.	...	...	...	...	...	...	...	...	...	...	...	...	...
7 9 5	-5	3	12	14	7	167,9	273,4	- 58,1	412,3	- 532,6	229,6	- 124,4,2	Reg.
7 9 6	-6	-6	0	10	8	168,2	249,8	73,5	367,8	- 544,6	201,1,4	980,8	Reg.
7 9 7	-12	-12	12	3	-15	157,3	292,4	183,1	- 212,2	- 265,8	331,3,9	- 215,5,4	Reg.
7 9 8	-9	4	17	4	-9	158,1	337,3	- 205,5	263,7	- 73,9	187,0,6	- 107,9,1	Reg.
7 9 9	2	0	5	9	11	186,9	134,0	430,3	-1,3	331,2	90,6	302,9	Reg.

Os bancos de dados criados, vide seção 5.3, para as três condições analisadas, vide seção 5.4, podem ser acessados, na sua íntegra, no repositório de bancos de dados *Mendeley*, através do link: <https://data.mendeley.com/datasets/cn6dk6f77y/1>.



## 6. Resultados e Discussões

A partir dos capítulos 2 a 4, pode-se, executando-se os modelos de aprendizado de máquina, conferir quais deles apresentam melhor desempenho, em cada uma das nove condições analisadas, quais sejam:

- ✓ Navio docado – bancos de dados 1, 2 e 3;
- ✓ Navio frio – bancos de dados 1, 2 e 3; e
- ✓ Navio quente – bancos de dados 1,2 e 3.

Desta forma, e já com a métrica de avaliação apropriada ao problema analisado, sendo ela a métrica de *Precisão*, pôde-se confrontar os resultados dos modelos para cada um dos algoritmos testados.

### 6.1. Resultados dos modelos de ML

Os resultados obtidos, já levando-se em consideração o refinamento dos hiperparâmetros dos algoritmos, são apresentados a seguir. Destaca-se uma vez mais que, variando-se os hiperparâmetros dos algoritmos, buscou-se não somente as melhores taxas de precisão, mas também, modelos menos enviesados e mais generalistas, tornando-os cada vez mais confiáveis quando da submissão destes a dados novos. Para isso, a faixa de variação dos mesmos foi selecionada também tentando evitar problemas relacionados ao sobreajuste. Tal seleção dos hiperparâmetros, variou entre os modelos baseando-se nas referências utilizadas para cada um dos algoritmos testados em específico.

#### 6.1.1. *Extremely randomized trees*

Nos modelos de árvores extremamente aleatórias, tal qual o apresentado nos trabalhos de (ESLAMI, SALMAN, *et al.*, 2020, GEURTS, ERNST, *et al.*, 2006), variaram-se os seguintes hiperparâmetros:

- i. Número de árvores (*n\_estimators*): [20, 50, 100];
- ii. Número mínimo de amostras para dividir um nó (*min\_samples\_split*): [2, 5, 8, 11];
- iii. Máxima profundidade da árvore (*max\_depth*): [7, 10, 15, 19];

- iv. Número mínimo de amostras em uma folha (*min\_samples\_leaf*): [1, 2, 3, 7]; e
- v. Função para medir a qualidade do corte (*criterion*): [entropia, gini].

Desta forma, foi a partir da variação destes valores, que os resultados refinados foram obtidos, sendo apresentados a seguir na Tabela 5.

Tabela 5: Resultados – modelos de *Extra-trees*

<b>Condição 1</b>		<b><i>Extra Trees</i></b>		
<b>Bancos</b>	<b>Precisão Média</b>	<b>Revocação</b>	<b>F1-Score</b>	<b>Acurácia</b>
1	88,47%	88,12%	87,99%	88,12%
2	92,80%	92,50%	92,51%	92,50%
3	<b>94,22%</b>	93,75%	93,90%	93,75%

<b>Condição 2</b>		<b><i>Extra Trees</i></b>		
<b>Bancos</b>	<b>Precisão Média</b>	<b>Revocação</b>	<b>F1-Score</b>	<b>Acurácia</b>
1	90,54%	90,00%	89,90%	90,00%
2	92,76%	92,50%	92,51%	92,50%
3	<b>94,73%</b>	94,35%	94,47%	94,35%

<b>Condição 3</b>		<b><i>Extra Trees</i></b>		
<b>Bancos</b>	<b>Precisão Média</b>	<b>Revocação</b>	<b>F1-Score</b>	<b>Acurácia</b>
1	86,76%	86,25%	86,16%	86,25%
2	90,27%	90,00%	90,07%	90,00%
3	<b>93,39%</b>	92,86%	92,93%	92,86%

Os resultados obtidos pelos modelos que utilizaram os conceitos das *Extra-Trees*, ainda não foram suficientemente altos para atender à premissa de se obter um classificador com ao menos 95,00% de *Precisão*. Desta forma, tentou-se obter melhores resultados através de outros modelos, utilizando-se outros algoritmos, ao invés de estressar ainda mais este modelo, através da variação de uma gama ainda maior de seus hiperparâmetros.

### 6.1.2. Random Forest (RF)

No processo de refinamento dos modelos de floresta aleatória, variaram-se os seguintes parâmetros, com base nas referências (NADI, MORADI, 2019, SALLES, GONÇALVES, *et al.*, 2018):

- i. Número de árvores (*n\_estimators*): [20, 50, 100];
- ii. Número mínimo de amostras para dividir um nó (*min\_samples\_split*): [2, 5, 7, 11];
- iii. Máxima profundidade da árvore (*max\_depth*): [5, 7, 10, 15, 19] \* Não há limite de profundidade máxima quando se utiliza os parâmetros padrões deste algoritmo;
- iv. Número mínimo de amostras em uma folha (*min\_samples\_leaf*): [1, 3, 5].

A Tabela 6 resume os resultados obtidos para os nove conjuntos de cenários analisados, como segue:

Tabela 6: Resultados – modelos de *Random Forest*

Condição 1	<i>Random Forest</i>			
Bancos	Precisão Média	Revocação	F1-Score	Acurácia
1	94,48%	94,37%	94,36%	94,37%
2	97,21%	97,19%	97,19%	97,19%
3	<b>97,64%</b>	97,62%	97,63%	97,62%

Condição 2	<i>Random Forest</i>			
Bancos	Precisão Média	Revocação	F1-Score	Acurácia
1	94,58%	94,37%	94,36%	94,37%
2	96,66%	96,56%	96,58%	96,56%
3	<b>96,77%</b>	96,73%	96,73%	96,73%

Condição 3	<i>Random Forest</i>			
Bancos	Precisão Média	Revocação	F1-Score	Acurácia
1	95,23%	95,00%	95,00%	95,00%
2	95,08%	94,69%	94,76%	94,69%
3	<b>96,45%</b>	96,43%	96,41%	96,43%

Os resultados obtidos foram maiores do que o mínimo estipulado em sete dos nove casos estudados e, nos bancos de dados com maior número de amostras, todos os resultados foram superiores. O valor máximo de *Precisão* obtido foi de **97,64%** de precisão na condição 1, utilizando-se o banco de dados 3, com os seguintes parâmetros:

- i. Número de árvores: 100;
- ii. Número mínimo de amostras para dividir um nó: 5;
- iii. Máxima profundidade da árvore: 15;
- iv. Número mínimo de amostras em uma folha: 1.

### 6.1.3. Gradient Boosting (GB)

De forma análoga aos dois algoritmos que também utilizam o método *ensemble* apresentados anteriormente, para os modelos que utilizam o algoritmo de *Gradient Boosting*, também variaram-se os seguintes parâmetros (BLAGUS, LUSA, 2017, TABRIZCHI, TABRIZCHI, *et al.*, 2020):

- i. Número de árvores (*n\_estimators*): [20, 50, 100];
- ii. Número mínimo de amostras para dividir um nó (*min\_samples\_split*): [2, 5, 7, 11];
- iii. Máxima profundidade da árvore (*max\_depth*): [3, 5, 7, 10, 15, 19];
- iv. Número mínimo de amostras em uma folha (*min\_samples\_leaf*): [1, 3, 5].

Os resultados obtidos para essas condições são apresentados na Tabela 7 a seguir.

Tabela 7: Resultados – modelos GB

Condição 1	Gradient Boosting			
Bancos	Precisão Média	Revocação	F1-Score	Acurácia
1	93,31%	93,13%	93,06%	93,13%
2	<b>98,14%</b>	98,12%	98,13%	98,12%
3	97,93%	97,92%	97,92%	97,92%

Condição 2	Gradient Boosting			
Bancos	Precisão Média	Revocação	F1-Score	Acurácia
1	94,63%	94,37%	94,34%	94,37%
2	<b>97,85%</b>	97,81%	97,82%	97,81%
3	97,32%	97,32%	97,32%	97,32%

Condição 3	Gradient Boosting			
Bancos	Precisão Média	Revocação	F1-Score	Acurácia
1	93,66%	93,13%	93,08%	93,13%
2	95,22%	95,00%	95,05%	95,00%
3	<b>96,15%</b>	96,13%	96,10%	96,13%

Analisando-se a Tabela 7, mais uma vez observam-se resultados superiores a 95,00% em todos os casos com exceção daqueles relativos ao banco 1, o de menor número de amostras. A maior *Precisão* obtida foi de **98,14%**, foi obtida na condição 1, banco 2, sendo o melhor resultado obtido nos 27 cenários analisados (3 condições, 3 bancos de dados e 3 diferentes modelos), cujos parâmetros que retornaram tais valores foram:

- i. Número de árvores: 50;
- ii. Número mínimo de amostras para dividir um nó: 7;
- iii. Máxima profundidade da árvore: 10;
- iv. Número mínimo de amostras em uma folha: 1.

## 6.2. Resultados das Redes Neurais Profundas

Em vista dos resultados obtidos nos demais modelos, cujos resultados foram muito parecidos com os dois últimos bancos de dados foram obtidos, decidiu-se, neste caso, um maior enfoque nas configurações das redes neurais, bem como no refinamento dos seus parâmetros (diferentes otimizadores, técnicas de combate ao *overfitting*, etc.) ao invés da obtenção de resultados para os três bancos de dados.

Neste contexto, optou-se por analisar os resultados a serem obtidos com o banco de dados número 3, uma vez que este representa uma condição mais próxima ao cenário observado no procedimento de alinhamento de eixo, onde há uma incidência de resultados “ruins” mais significativa em relação às demais classes.

Face ao exposto, optou-se ainda por analisar três otimizadores diferentes (KERAS, 2022), tais como o *Gradiente Estocástico Descendente (SGD)*, *Adam* e *RMSprop*, para uma mesma configuração de rede neural a ser implementada somente no banco de dados 3. Neste contexto, as redes testadas tiveram a seguinte configuração:

- i. Rede Neural Sequencial e Densa, ou seja, redes totalmente conectadas, onde os neurônios da camada anterior se comunicam com os da camada seguinte;
- ii. O *kernel* de inicialização utilizado em todas as camadas foi o *kernel* de distribuição “Normal” (“Deep Learning Book”, 2022);
- iii. Camada de entrada com 12 neurônios – número igual ao das variáveis preditoras remanescentes após as etapas de pré-processamento e seleção de variáveis;
- iv. Rede com 2 camadas ocultas, com 100 neurônios em cada. Definição feita pelo autor baseando-se na referência (“Deep Learning Book”, 2022);
- v. A função de erro escolhida foi a de entropia cruzada (*cross entropy*);
- vi. A função de ativação das camadas intermediárias utilizada foi a função “*Relu*”, vide Apêndice C – Funções de Ativação (“Deep Learning Book”, 2022);
- vii. A função de ativação da camada de saída foi a função “*Softmax*”, (“Deep Learning Book”, 2022, MÜLLER, GUIDO, 2016), conforme apresentado no Apêndice C – Funções de Ativação;
- viii. Foram utilizados 80% do banco de dados como dados de treino e 20% como dados de teste, valores esses utilizados de forma padrão (NAKATSU, 2021);

- ix. Foi utilizada uma camada de saída com 4 neurônios (um para cada classe de saída possível).

Outrossim, os modelos de redes neurais, assim como os demais modelos de aprendizagem de máquina apresentados nessa dissertação, foram rodados na plataforma *Jupyter Notebook*, utilizando-se mais uma vez da linguagem *Python*. Para a confecção das redes neurais artificiais profundas, foi utilizado o *framework Keras* (que é uma biblioteca contendo códigos, principalmente voltada para aplicação de redes neurais), cuja função principal é permitir a criação e experimentação de redes neurais para a resolução dos mais variados problemas (“About Keras”, 2022). Tal *framework* trata-se de uma ferramenta amplamente utilizada em setores ligados ao desenvolvimento de modelos de inteligência artificial e aprendizagem de máquinas, principalmente tratando-se de modelos que empregam as redes neurais artificiais.

Além disso, redes neurais artificiais profundas costumam sofrer do problema de sobreajuste (*overfitting*), onde o modelo, fica muito ajustado aos dados de treino, mas quando expostos a novos dados, dados de teste, não conseguem atingir valores de predições próximos aos obtidos anteriormente, com os dados de treinamento. Deste modo, duas técnicas muito utilizadas no combate a esse problema também foram implementadas nos modelos. São elas as técnicas de regularização e de *dropout* (“Deep Learning Book”, 2022). Esta última trata-se de uma técnica onde desliga-se, de maneira aleatória, uma porcentagem dos neurônios da rede, visando tornar o modelo mais generalista e menos propenso ao problema de sobreajuste. Detalhes específicos dessas técnicas foram citados quando da apresentação dos resultados dos modelos que as utilizaram, subseções 6.2.1, 6.2.2 e 6.2.3.

A seguir apresentam-se os resultados obtidos para cada um dos três otimizadores utilizados, e aplicam-se os mesmos conceitos de variação dos hiperparâmetros empregados nos demais modelos até aqui estudados, buscando-se, uma vez mais, melhores taxas de precisão.

### 6.2.1. Adam

Dois cenários foram analisados para esse e para os demais otimizadores selecionados. O primeiro, modelo 1, não utilizou as técnicas de combate ao sobreajuste, enquanto que no modelo 2, essas técnicas foram aplicadas. A regularização utilizada foi a L2 (0,01), sendo aplicada em ambas as camadas ocultas. De forma análoga, foi aplicada à essas mesmas camadas do modelo 2 a técnica do *dropout*, apagando-se aleatoriamente 20% dos neurônios. Os seguintes resultados foram obtidos, como segue:

#### a) Adam

Parâmetros do otimizador Adam utilizados no modelo 1:

- i. Taxa de aprendizagem: 0,001;
- ii. Beta\_1: 0,9;
- iii. Beta\_2: 0,999;
- iv. Épsilon ( $\epsilon$ ): 1e-7; e
- v. Amsgrad: *False*.

Com esses valores de parâmetros, associados a um lote de 100 amostras, chegou-se, após um processo de 1.000 épocas, vide Figura 14, a um processo iterativo de tamanho suficiente para observar a estabilização dos resultados com os valores sendo apresentados na Tabela 8 e ilustrados na Figura 14:

Tabela 8: Resultados do otimizador Adam

<b>Modelo 1</b>	<b>Adam</b>			
Banco de dados 3	Precisão Treino	Precisão Teste	Entropia Cruzada Treino	Entropia Cruzada Teste
	98,44%	92,26%	0,0537	0,2111

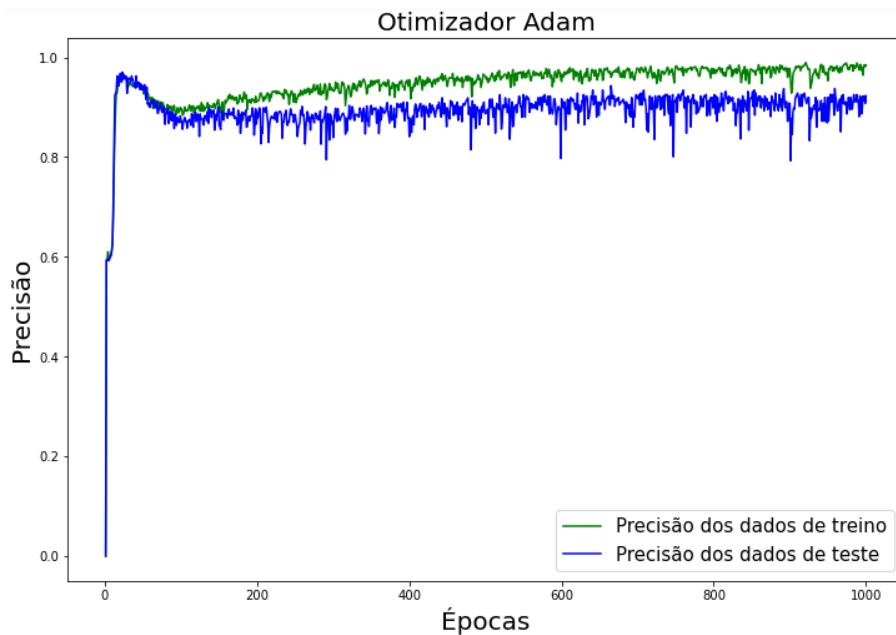


Figura 14: Otimizador Adam

Através dos dados apresentados na Tabela 8 e na Figura 14, torna-se possível observar a presença do sobreajuste afetando o desempenho do modelo. Neste sentido, destaca-se o descolamento (*gap*) de 6,18% (vide as diferenças dos resultados apresentados na Tabela 8) entre os resultados obtidos com os dados de treino e os obtidos com os dados de teste.

Desta forma, apesar dos bons resultados apresentados para os dados de treino, 98,44% de precisão média, observa-se uma considerável queda nos resultados para os dados de teste, 92,26%. Como estes são os mais importantes na hora de se determinar se um modelo é de fato confiável, uma vez que na maioria dos casos, o modelo será submetido a valores distintos daqueles presentes em seus(s) banco(s) de dados.

Em suma, quando são comparados os resultados obtidos com os modelos apresentados nas subseções 6.1.1, 6.1.2 e 6.1.3, principalmente comparando-os com os modelos que utilizaram os algoritmos de *Random Forest* e de *Gradient Boosting*, observa-se mais segurança nesses últimos, uma vez que os resultados para os dados de teste destes modelos retornaram valores melhores e não foram constatadas evidências da presença de sobreajuste em tais cenários.



b) *Adam* com regularização L2 e *Dropout*

Ressaltada a iminência do problema do sobreajuste, decidiu-se, então, considerar-se a aplicação das técnicas de regularização L2 (0,01) e de *dropout*, levando-se em conta um desligamento de 20% dos neurônios das duas camadas ocultas. Desta maneira, os resultados obtidos para o modelo 2, vide Tabela 9 e Figura 15, foram tais que:

Tabela 9: Resultados Adam + Regularização L2 e *Dropout*

<b>Modelo 2</b>	<b>Adam – Regularização L2 + Dropout</b>			
Banco de dados 3	Precisão Treino	Precisão Teste	Entropia Cruzada Treino	Entropia Cruzada Teste
	90,93%	90,24%	0,4423	0,4521

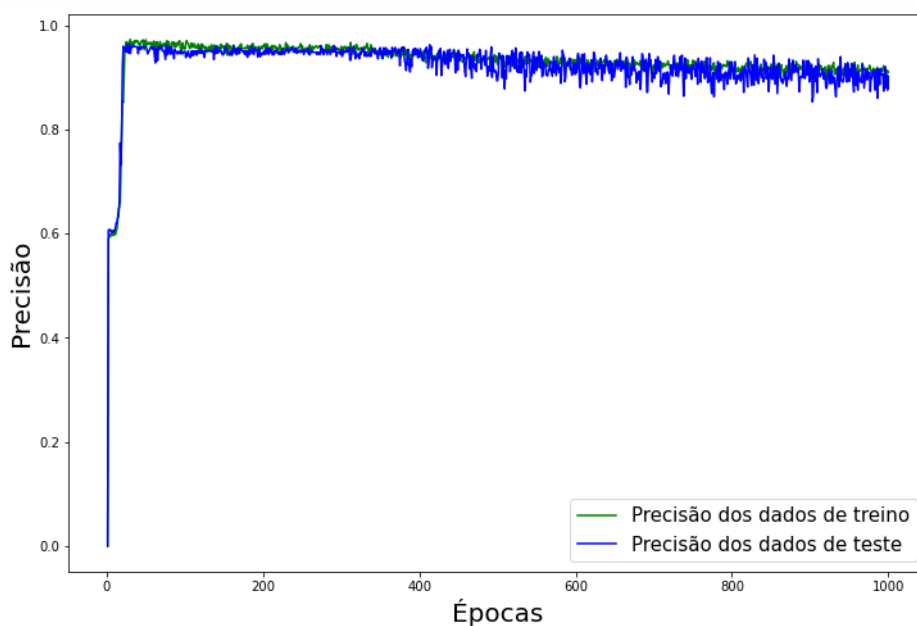


Figura 15: Otimizador Adam com regularização L2 e *Dropout*

Os resultados apresentados na Tabela 9 e na Figura 15, apresenta uma diminuição significativa do *gap* entre os resultados dos dados de treino e de teste, totalizando 0,69%, atestando para uma contribuição significativa das técnicas de combate ao sobreajuste.

Apesar dessa contribuição, onde chegou-se a um modelo mais confiável em relação à não ocorrência do sobreajuste, os resultados obtidos foram altamente penalizados, não superando os 95,00% mínimos desejados. Outras variações de hiperparâmetros

poderiam ser testadas em busca de melhores resultados, no entanto, haja visto os bons resultados já obtidos nos demais modelos (usando o *GB* e o *RF*, por exemplo), decidiu-se verificar se os resultados obtidos por outros otimizadores seriam mais interessantes.

Por fim, acredita-se que estes baixos desempenhos tenham se dado pelo número de amostras do banco de dados analisado (1.673 amostras) e pelo número de variáveis preditoras não serem tão grandes, uma vez que se recomenda a utilização desse otimizador para conjuntos de dados contendo mais amostras conforme o apresentado pela referência (KINGMA, BA, 2014).

### 6.2.2. *RMSprop*

Para este otimizador, uma vez mais, dois modelos de rede neural profunda foram criados, os terceiro e quarto modelos apresentados a seguir. O modelo 3 é aquele com os parâmetros padrões do otimizador, e o quarto modelo, aquele com a aplicação das técnicas de regularização L2 e *dropout*. Os resultados obtidos foram os seguintes:

#### a) *RMSprop*

Parâmetros do otimizador *RMSprop* utilizados no modelo 3:

- i. Taxa de aprendizagem: 0,001;
- ii. *Rho* ( $\rho$ ): 0,9;
- iii. *Momentum*: 0,0;
- iv. Épsilon ( $\epsilon$ ): 1e-7; e
- v. *Centered*: *False*.

Com esses valores de parâmetros, associados a novamente um lote de 100 amostras, chegou-se, após um processo de iteração de 1000 épocas, aos seguintes resultados de precisão, e de função de erro de entropia cruzada, Tabela 10 e Figura 16:

Tabela 10: Resultados otimizador *RMSprop*

<b>Modelo 3</b>	<b><i>RMSprop</i></b>			
Banco de dados 3	Precisão Treino	Precisão Teste	Entropia Cruzada Treino	Entropia Cruzada Teste
	93,27%	88,06%	0,1466	0,2896

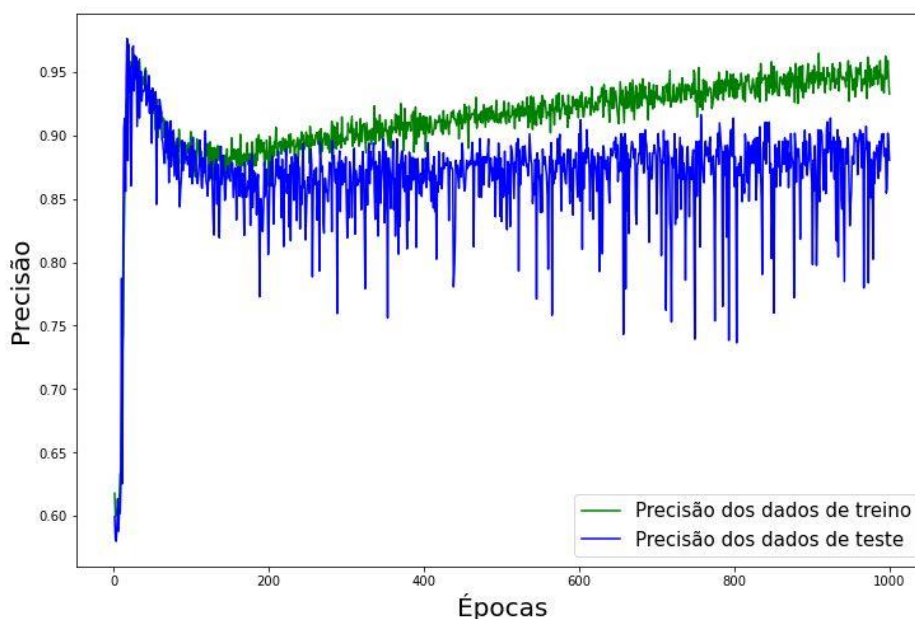


Figura 16: Otimizador *RMSprop*

Observa-se na Figura 16 o problema de sobreajuste, com os resultados obtidos com os dados de treino sendo bem superiores aos obtidos com os dados de teste. Tal discrepância, vide Tabela 10, separa em mais de 5 por cento (5,21%) os resultados, indicando mais uma vez um sobreajuste do modelo. Desta maneira, não se chegou a uma alta confiabilidade no modelo 3, principalmente diante dos problemas observados e associados às baixas precisões obtidas ao se analisar os dados de teste, 88,06%.

Observa-se na Figura 16, uma tendência de melhora nas precisões médias somente nos dados de treino com o passar das épocas, enquanto os resultados com os dados de teste já se mostram mais constantes e sem maiores melhorias de resultados.

b) *RMSprop* com regularização L2 e *Dropout*

A partir do problema supracitado, decidiu-se mais uma vez implementar as técnicas de regularização L2 (0,01) e *dropout* (20%) como fora feito anteriormente no otimizador *Adam*. Neste contexto, os resultados obtidos, Tabela 11 e Figura 17, foram tais que:

Tabela 11: Resultados *RMSprop* + Regularização L2 e *Dropout*

<b>Modelo 4</b>	<b><i>RMSprop</i> + Regularização L2 + <i>Dropout</i></b>			
Banco de dados 3	Precisão Treino	Precisão Teste	Entropia Cruzada Treino	Entropia Cruzada Teste
	89,36%	85,43%	0,4547	0,4567

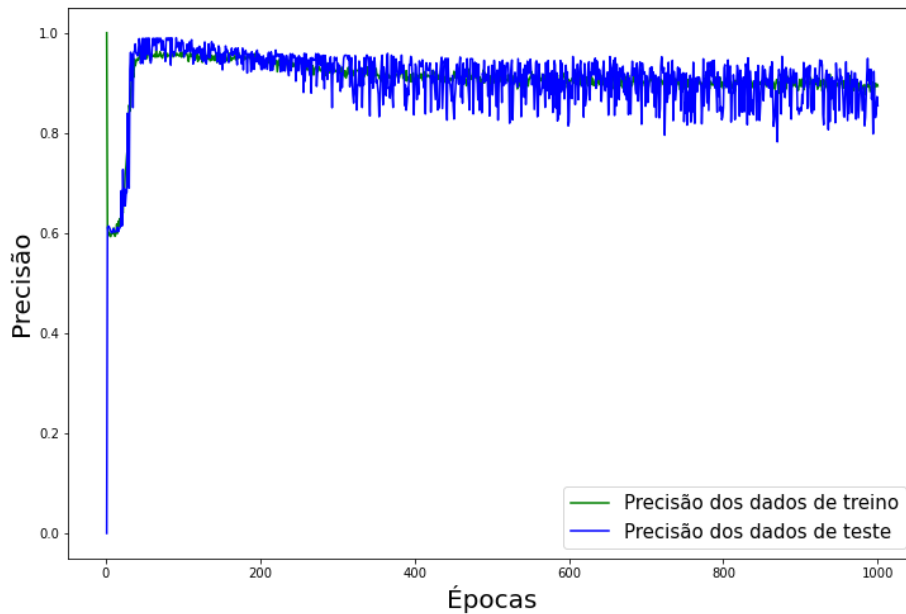


Figura 17: Otimizador *RMSprop* com regularização L2 e *Dropout*

Com base no apresentado na Tabela 11 e na Figura 17, a aplicação das técnicas de regularização levaram à uma ligeira redução das diferenças de precisão dos dados de treino e teste, embora com grandes oscilações nos resultados a cada nova época e degradações significativas dos resultados obtidos.

Muitas outras combinações de parâmetros poderiam ser aplicadas, e talvez, resultando em melhoras significativas. No entanto, para os fins estabelecidos no início dessa dissertação, os resultados obtidos pelos algoritmos de aprendizado de máquina expostos em 6.1, já permitem a obtenção de taxas de predições mais significativas, com valores de precisão considerados satisfatórios para a implementação de tais modelos.

### 6.2.3. *Gradiente estocástico descendente (SGD)*

Outra vez, portanto, executaram-se dois modelos utilizando o algoritmo SGD. O primeiro modelo criado, utilizando-se o otimizador SGD com seus parâmetros padrões (*default*), já o segundo modelo contando com a aplicação da regularização L2 e do *dropout* nas duas camadas ocultas, nos mesmos moldes das subseções anteriores. Os resultados obtidos, Tabela 12 e Figura 18, são agora apresentados.

a) *SGD*

Parâmetros do otimizador *SGD* utilizados no modelo 5:

- i. Taxa de aprendizagem (*learning rate*): 0,01;
- ii. *Momentum*: 0,00; e
- iii. *Nesterov*: 0,00.

Com esses valores de parâmetros, associados a um lote de 100 amostras, chegou-se, após um processo de iteração de 1000 épocas, vide Tabela 12 e Figura 18, a um platô quase paralelo onde nova iterações pouco contribuem para melhores resultados. Dito isto, os resultados obtidos foram tais que:

Tabela 12: Resultados otimizador *SGD*

<b>Modelo 5</b>	<b><i>SGD</i></b>			
Banco de dados 3	Precisão Treino	Precisão Teste	Entropia Cruzada Treino	Entropia Cruzada Teste
	96,39%	94,52%	0,4202	0,4844

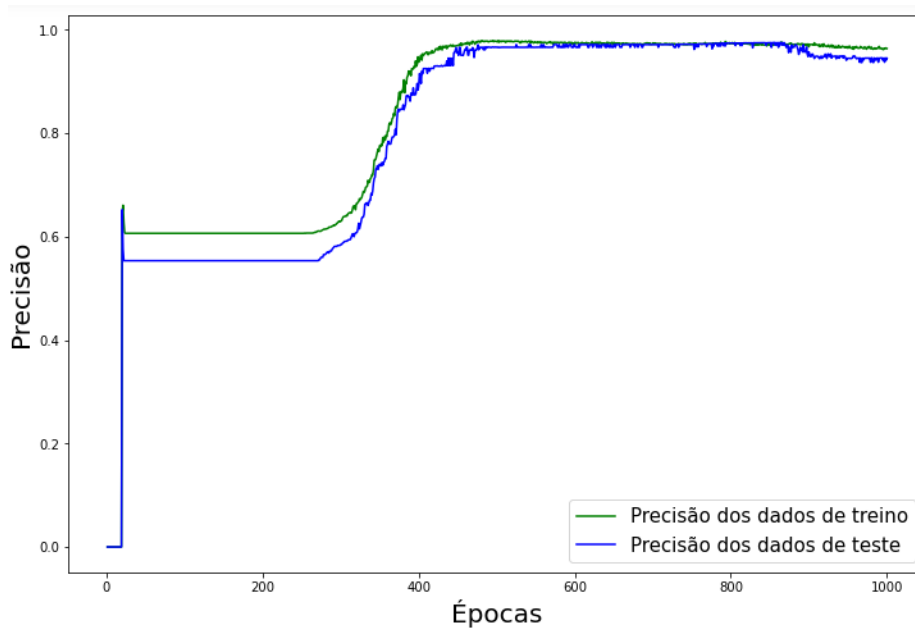


Figura 18: Otimizador *SGD*

Considerando-se os resultados deste modelo, representados pela Figura 18, não há, após a estabilização dos resultados, aproximadamente entre 550 e 850 épocas, evidências de que o modelo esteja sofrendo com problemas de sobreajuste, uma vez

que os resultados dos dados de teste caminham juntos com os de treinamento. No entanto, por volta das 150 últimas iterações, observaram-se sinais de alerta para tal problema. Onde o distanciamento entre resultados começa a aumentar, e os resultados dos dados de teste começam a diminuir ligeiramente em relação aos resultados dos dados de treino. Desta forma, julgou-se necessária, a aplicação das técnicas de regularização, buscando-se combater esta ocorrência, cujos resultados são apresentados a seguir.

b) *SGD* com regularização L2 e *Dropout*

Uma vez mais, portanto, analisou-se um novo modelo, utilizando as técnicas de regularização L2 (0,01) e de *dropout* (“Deep Learning Book”, 2022), em ambas as camadas ocultas, cujos resultados obtidos, Tabela 13 e Figura 19, foram tais que:

Tabela 13: Resultados *SGD* + Regularização L2 e *Dropout*

<b>Modelo 6</b>	<b><i>SGD</i> + Regularização L2 + <i>Dropout</i></b>			
Banco de dados 3	Precisão Treino	Precisão Teste	Entropia Cruzada Treino	Entropia Cruzada Teste
	97,44%	96,61%	0,7577	0,8383

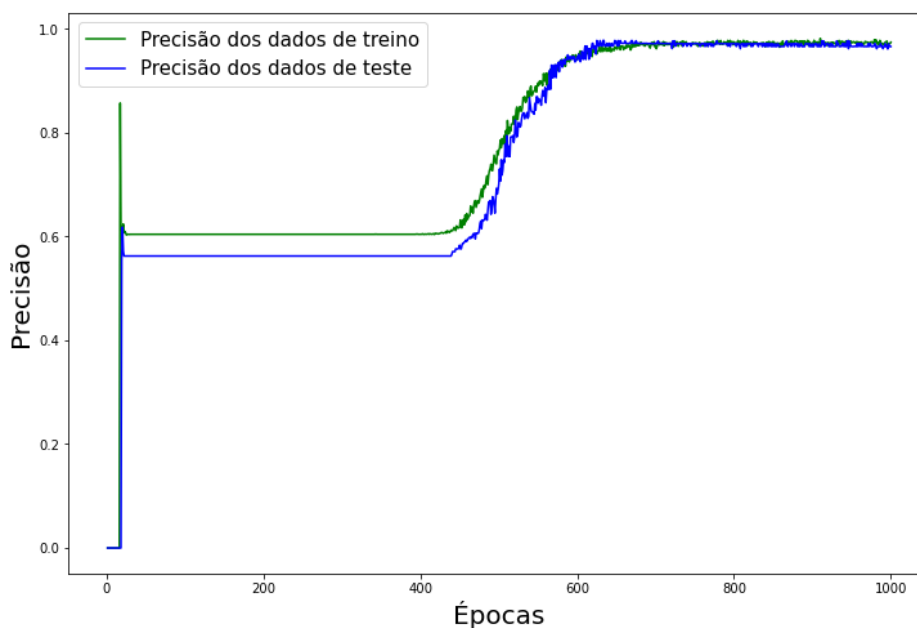


Figura 19: *SGD* com regularização L2 e *Dropout*

Na Figura 19 pode-se observar que os dados de treino e de teste continuam caminhando juntos até o término das 1000 épocas. Deste modo, os indícios da presença de sobreajuste observados no modelo 5, principalmente na faixa final do processo iterativo, já não são mais observados neste modelo, atestando para a importância da aplicação dos métodos de regularização.

Finalmente, chegou-se, assim, a um modelo de árvores neurais profundas, modelo 6, confiável e capaz de predizer os resultados corretos com um valor de precisão média considerável, no valor de 96,61%, e acima do valor mínimo aceitável estipulado inicialmente.

## 7. Conclusões e Recomendações

As altas taxas de precisão observadas, principalmente nos melhores modelos de *Gradient Boosting* – 98,14%, *Random Forest* – 97,64% e RN profundas utilizando o otimizador SGD – 96,61%, foram consideradas satisfatórias e acima do limite mínimo previamente estabelecido, ou seja, de 95,00%. A Figura 20 apresenta os quatro melhores modelos de cada um dos algoritmos utilizados, explicitando os seus desempenhos em termos de suas *Precisões médias*, *Acurácias*, *F1-scores* e *Revocação*.

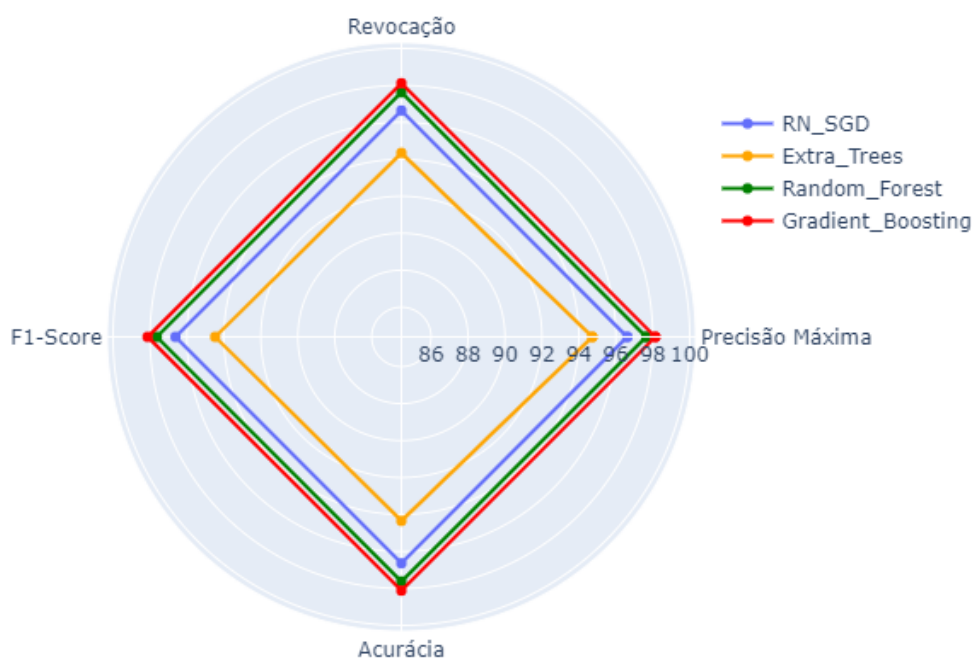


Figura 20: Comparação dos melhores resultados de cada modelo

Em síntese, de posse de todos os valores que impactam na movimentação dos mancais de uma determinada embarcação, sejam eles devido às deflexões do casco, aos desgastes dos mancais, ou ainda às dilatações térmicas, pode-se refinar os bancos de dados para limites inferiores e superiores que atendam à todas essas condições. Ademais, tornando o banco mais específico para a embarcação analisada e seu respectivo sistema de eixo de propulsão principal. A partir daí, torna-se possível, aplicando-se modelos de aprendizado de máquina, a obtenção de valores de recalques que estabeleçam o atendimento às regras de alinhamento vigentes, tal qual o apresentado nesta dissertação. Esta técnica permite correções de desalinhamentos de



forma mais rápida e, retorna valores mais confiáveis do que os obtidos nas práticas de correção atualmente utilizadas (FARIAS, DOS REIS, *et al.*, 2021).

Acredita-se que esta dissertação, portanto, contribuiu para destacar a importância das ferramentas e algoritmos de aprendizagem de máquina, nesse caso em específico, o supervisionado, em problemas de correção de linhas de eixo desbalanceadas ou que precisem ser alinhadas em um eventual primeiro alinhamento.

Já os resultados de precisão obtidos foram considerados satisfatórios, principalmente os dos modelos de RF e GB, que tiveram médias de 96,01% e 96,02% respectivamente, considerando os nove cenários estudados. Além disso, observou-se, também, resultados consideráveis utilizando-se RN profundas, principalmente com o otimizador *SGD*, onde, acredita-se, que resultados ainda melhores são prováveis de serem obtidos, refinando-se mais os hiperparâmetros deste otimizador.

Outrossim, conforme explicado na seção 5.3 e suas subseções, compararam-se os resultados médios das precisões para cada um dos algoritmos em cada um dos bancos de dados. Deste modo, a Tabela 14 ilustra os resultados obtidos nesse contexto.

Tabela 14: Média das precisões por banco de dados e algoritmo

<b>Algoritmo <i>Extra-trees</i></b>		
<b>Média das Precisões Banco 1</b>	<b>Média das Precisões Banco 2</b>	<b>Média das Precisões Banco 3</b>
88,51%	92,19%	<b>94,12%</b>
<b>Algoritmo <i>Random Forest</i></b>		
<b>Média das Precisões Banco 1</b>	<b>Média das Precisões Banco 2</b>	<b>Média das Precisões Banco 3</b>
94,59%	96,22%	<b>96,81%</b>
<b>Algoritmo <i>Gradient Boosting</i></b>		
<b>Média das Precisões Banco 1</b>	<b>Média das Precisões Banco 2</b>	<b>Média das Precisões Banco 3</b>
93,48%	<b>96,96%</b>	96,88%

No menor dos bancos de dados estudado, banco 1, os modelos que executaram o algoritmo de RF, obtiveram as precisões mais altas, com média de 94,59%. Nos bancos de dados 2 e 3, os modelos que trabalharam com o algoritmo de *Gradient Boosting* obtiveram os melhores resultados com precisões médias de 96,96% e 96,88%, respectivamente.

Conclui-se, a partir dos resultados apresentados na Tabela 14, que o banco de dados 3, mesmo com o intencional desbalanceamento de classes, retornou resultados

consideravelmente próximos aos obtidos com o banco de dados balanceado, número 2. Ambos os bancos se alternaram como aqueles com os melhores resultados, sendo apresentada uma ligeira vantagem para o banco 3. Conseqüentemente, o procedimento de balanceamento de dados, realizado ainda na etapa de pré-processamento, pode vir a ser dispensável com base nos resultados obtidos neste estudo. No entanto, mais resultados que corroborem para essa teoria necessitam ser obtidos, assim como o número de amostras de cada banco precisa estar na mesma ordem de grandeza analisada ou com ainda mais dados.

Outrossim, espera-se que, com o aumento no número de testes, melhorias nos refinamentos, implementação de outros algoritmos, implementação de novas variáveis preditoras nos bancos de dados, o processo preditivo para este problema seja ainda mais eficaz, reduzindo-se o tempo e os recursos gastos nos trabalhos de alinhamento, bem como provendo uma maior confiança na otimização deste e de outros trabalhos similares a bordo das embarcações.

Ressalta-se o caráter de originalidade desta dissertação, tanto da concepção do banco de dados, quanto da implementação de inteligência artificial, através de modelos de aprendizagem de máquina, na solução de problemas multiclases e de grande importância tanto para a manutenção da operacionalidade do sistema de eixo principal, quanto para a confiabilidade do sistema propulsivo da embarcação.

Finalmente, algumas das principais conclusões que se podem tirar desta dissertação são tais que:

- ✓ Os melhores modelos dos algoritmos *Random Forest*, Redes Neurais e *Gradient Boosting* superaram a taxa de predição estipulada inicialmente;
- ✓ Houve a necessidade de mitigar problemas relacionados ao sobreajuste nos modelos de Redes Neurais, onde a aplicação de técnicas de regularização (*dropout*, regularização L2) agregou significativo valor aos resultados obtidos;
- ✓ Os modelos desenvolvidos se mostraram robustos o suficiente para trabalhar com bancos de dados desbalanceados;
- ✓ A confecção de bancos de dados com ainda mais amostras tende a produzir modelos ainda mais confiáveis; e
- ✓ A busca por um método orientado de alinhamento de LE principal se mostrou viável a partir da implementação das técnicas de ML.

## 7.1. Trabalhos Futuros

A partir do trabalho apresentado nessa dissertação, pôde-se ter uma maior consciência do quanto ainda pode ser desbravado com as ferramentas de inteligência artificial e aprendizagem de máquinas voltadas para as mais diversas áreas da engenharia. Estas ferramentas ainda são pouco ou nada aplicadas, como mostra o conteúdo observado na revisão bibliográfica, principalmente na área de alinhamento de eixos principais de navios, foco principal desta dissertação.

Após todos os resultados e conclusões apresentados, acredita-se que criações de novos modelos, variando-se ainda mais seus hiperparâmetros, devem fornecer melhores resultados, contribuindo assim para a disseminação da utilização de modelos de ML no processo de alinhamento de eixos principais nos estaleiros.

Além disso, estudar outras variáveis preditoras presentes no sistema de eixo principal dos navios, agregando-as a essa linha de estudo apresentada e testadas com diferentes algoritmos, pode corroborar com uma boa confiabilidade às previsões de recalques que garantam um correto alinhamento de demais linhas de eixos, linhas estas eventualmente com configurações distintas da aqui apresentada.

Por fim, produzir bancos de dados e, por conseguinte, modelos que levem em consideração tanto as deflexões dos cascos das embarcações, quanto as influências das condições dinâmicas nos recalques e, conseqüentemente, nas reações que os mancais e linha de eixo estarão submetidos, podem impactar positivamente nos resultados. Nestes casos, obter-se-iam assim, valores ainda mais específicos para cada sistema estudado, e, portanto, atendendo aos cenários encontrados nos navios quando em operação. Desta forma, acredita-se ser possível reduzir sensivelmente os problemas comumente observados nas linhas de eixo dos navios atuais.

## 8. Referências Bibliográficas

About Keras. 5 set. 2022. Keras. Disponível em: <https://keras.io/about/>. Acesso em: 4 set. 2022.

AMARI, S.-I. Backpropagation and stochastic gradient descent method. Neurocomputing. [S.l: s.n.], 1993.

AMERICAN BUREAU OF SHIPPING. Guidance Notes on Propulsion Shafting Alignment. [S.l: s.n.], set. 2019. Disponível em: [www.eagle.org](http://www.eagle.org). Acesso em: 15 jul. 2022.

BLAGUS, R., LUSA, L. "Gradient boosting for high-dimensional prediction of rare events", Computational Statistics and Data Analysis, v. 113, p. 19–37, 1 set. 2017. DOI: 10.1016/j.csda.2016.07.016.

BREIMAN, L. "Random Forests", Machine Learning, v. 45, p. 5–32, 2001.

BUDYNAS, R. G. (Richard G., NISBETT, J. Keith., SHIGLEY, J. Edward. Shigley's mechanical engineering design. [S.l.], McGraw-Hill, 2011.

CHAWLA, N. V, BOWYER, K. W., HALL, L. O., *et al.* "SMOTE: Synthetic Minority Over-sampling Technique", Journal of Artificial Intelligence Research, v. 16, p. 321–357, 2002.

CHENG, H., WU, L., LI, R., *et al.* "Data recovery in wireless sensor networks based on attribute correlation and extremely randomized trees", Journal of Ambient Intelligence and Humanized Computing, v. 12, n. 1, p. 245–259, 1 jan. 2021. DOI: 10.1007/s12652-019-01475-z.

CHOI, S. P., LEE, J. U., PARK, J. B. "Application of deep reinforcement learning to predict shaft deformation considering hull deformation of medium-sized oil/chemical tanker", Journal of Marine Science and Engineering, v. 9, n. 7, p. 1–30, 1 jul. 2021. DOI: 10.3390/jmse9070767.

Deep Learning Book. 2022. Data Science Academy. Disponível em: <https://www.deeplearningbook.com.br/funcao-de-ativacao/>. Acesso em: 7 set. 2022.

DNV GL. Rules for Classification. [S.l: s.n.], jul. 2017. Disponível em: <http://www.dnvgl.com>. Acesso em: 24 ago. 2022.

DUARTE, Y. S., BAPTISTA, L. A. R., PINTO, L. A. V. "Optimization applied to bearing displacement determination for ship propulsion shafts", Marine Systems and Ocean Technology, v. 16, n. 3–4, p. 246–254, 1 dez. 2021. DOI: 10.1007/s40868-021-00108-5.

ESLAMI, E., SALMAN, A. K., CHOI, Y., *et al.* "A data ensemble approach for real-time air quality forecasting using extremely randomized trees and deep neural networks", *Neural Computing and Applications*, v. 32, n. 11, p. 7563–7579, 1 jun. 2020. DOI: 10.1007/s00521-019-04287-6.

FARIAS, DOS REIS, M., ANTÔNIO, L., *et al.* "Key calculation considerations, measurement, and corrections of ship propulsion shaft alignment". 2021. Rio de Janeiro, [s.n.], 2021.

FERNÁNDEZ-DELGADO, M., CERNADAS, E., BARRO, S., *et al.* "Do we Need Hundreds of Classifiers to Solve Real World Classification Problems?", *Journal of Machine Learning Research*, v. 15, p. 3133–3181, 2014. Disponível em: <http://www.mathworks.es/products/neural-network>.

GEURTS, P., ERNST, D., WEHENKEL, L. "Extremely randomized trees", *Machine Learning*, v. 63, n. 1, p. 3–42, abr. 2006. DOI: 10.1007/s10994-006-6226-1. .

KERAS. Optimizers. set. 2022. Keras. Disponível em: <https://keras.io/api/optimizers/>. Acesso em: 19 set. 2022.

KINGMA, D. P., BA, J. "Adam: A Method for Stochastic Optimization", 22 dez. 2014. Disponível em: <http://arxiv.org/abs/1412.6980>.

LANTZ, B. *Machine learning with R: learn how to use R to apply powerful machine learning methods and gain an insight into real-world applications*. 1. ed. [S.l: s.n.], 2013.

LEE, J. ung. "Application of strain gauge method for investigating influence of ship shaft movement by hydrodynamic propeller forces on shaft alignment", *Measurement: Journal of the International Measurement Confederation*, v. 121, p. 261–275, 1 jun. 2018. DOI: 10.1016/j.measurement.2018.02.067.

LEE, J. ung, JEONG, B., AN, T. H. "Investigation on effective support point of single stern tube bearing for marine propulsion shaft alignment", *Marine Structures*, v. 64, p. 1–17, 1 mar. 2019. DOI: 10.1016/j.marstruc.2018.10.010.

LEE, Y.-J., KIM, U.-K., KIM, J.-S. "Hull Deflections Affecting on the Ship's Propulsion Shafting Alignment in 46K Oil\_Chemical Carrier - OK", *Journal of the Korean Society of Marine Engineering*, v. 30, p. 800–807, 2006.

MARTINS, D. H. C. S. S., DE LIMA, A. A., PINTO, M. F., *et al.* "Hybrid data augmentation method for combined failure recognition in rotating machines", *Journal of Intelligent Manufacturing*, 2022. DOI: 10.1007/s10845-021-01873-1.

MHAWISH, M. Y., GUPTA, M. "Software Metrics and tree-based machine learning algorithms for distinguishing and detecting similar structure design patterns", SN Applied Sciences, v. 2, n. 1, 1 jan. 2020. DOI: 10.1007/s42452-019-1815-3.

MÜLLER, A. C., GUIDO, S. Introduction to Machine Learning with Python A guide for Data Scientists. 1. ed. [S.I.], O'Reilly, 2016.

NADI, A., MORADI, H. "Increasing the views and reducing the depth in random forest", Expert Systems with Applications, v. 138, p. 1–13, 30 dez. 2019. DOI: 10.1016/j.eswa.2019.07.018.

NAKATSU, R. T. "An Evaluation of Four Resampling Methods Used in Machine Learning Classification", IEEE Intelligent Systems, v. 36, n. 3, p. 51–57, 1 maio 2021. DOI: 10.1109/MIS.2020.2978066.

OUADAH, A., ZEMMOUCHI-GHOMARI, L., SALHI, N. "Selecting an appropriate supervised machine learning algorithm for predictive maintenance", International Journal of Advanced Manufacturing Technology, v. 119, n. 7–8, p. 4277–4301, 1 abr. 2022. DOI: 10.1007/s00170-021-08551-9.

PIOTROWSKI, JOHN. Shaft Alignment Handbook. 3rd. ed. [S.I: s.n.], 2007.

SALLES, T., GONÇALVES, M., RODRIGUES, V., *et al.* "Improving random forests by neighborhood projection for effective text classification", Information Systems, v. 77, p. 1–21, 1 set. 2018. DOI: 10.1016/j.is.2018.05.006.

SEO, C. O., JEONG, B., KIM, J. R., *et al.* "Determining the influence of ship hull deformations caused by draught change on shaft alignment application using FE analysis", Ocean Engineering, v. 210, p. 1–11, 15 ago. 2020. DOI: 10.1016/j.oceaneng.2020.107488.

SHAH, K., PATEL, H., SANGHVI, D., *et al.* "A Comparative Analysis of Logistic Regression, Random Forest and KNN Models for the Text Classification", Augmented Human Research, v. 5, n. 1, p. 1–16, dez. 2020. DOI: 10.1007/s41133-020-00032-0.

SNAME. "Practices and Procedures for the Alignment of Marine Main Propulsion Shafting Systems", 2007.

ŠVERKO, D. "Design concerns in propulsion shafting alignment", ABS Technical Papers, p. 1–13, 2003a.

ŠVERKO, D. "Hull deflections shaft alignment interaction, a case study", Proceedings of the 7th international symposium on marine engineering, p. 245–251, 2005.

ŠVERKO, D. "Shaft alignment optimization with genetic algorithms", ABS Technical Papers, 2003b.

TABRIZCHI, H., TABRIZCHI, M., TABRIZCHI, H. "Breast cancer diagnosis using a multi-verse optimizer-based gradient boosting decision tree", SN Applied Sciences, v. 2, n. 4, 1 abr. 2020. DOI: 10.1007/s42452-020-2575-9.

TAN, P.-N., STEINBACH, M., KUMAR, V. Introduction to Data Mining Instructor's Solution Manual. [S.l: s.n.], 2006.

## Apêndice A – Métricas de Avaliação

Dentre as métricas mais utilizadas em problemas de aprendizado de máquinas, como as abordadas por (MHAWISH, GUPTA, 2020, MÜLLER, GUIDO, 2016) em suas publicações, destacam-se as seguintes:

### A.1 Acurácia (*Accuracy*)

A *Acurácia* é dada pela Eq. (A.1):

$$\text{Acurácia} = \frac{VP+FP}{VP+VN+FP+FN} \quad (\text{A.1})$$

onde:

VP = verdadeiros positivos;

FP = falsos positivos;

VN = verdadeiros negativos; e

FN = falsos negativos.

Trata-se da divisão dos valores corretamente previstos (VP e FP), por todas as previsões efetuadas. Por esse motivo, a *Acurácia* é uma métrica recomendada quando se está trabalhando com dados balanceados. No entanto, ao se trabalhar com dados desbalanceados, tal métrica pode passar uma sensação equivocada de bom desempenho que pode estar associada aos acertos de uma única classe, justamente pelo seu maior número de amostras.

Utilizando-se o conceito de *matriz de confusão*, a *Acurácia* pode ser obtida, dividindo-se a soma da diagonal principal, destacada em azul, pela soma total dos elementos dessa matriz, conforme apresentado na Figura 21.



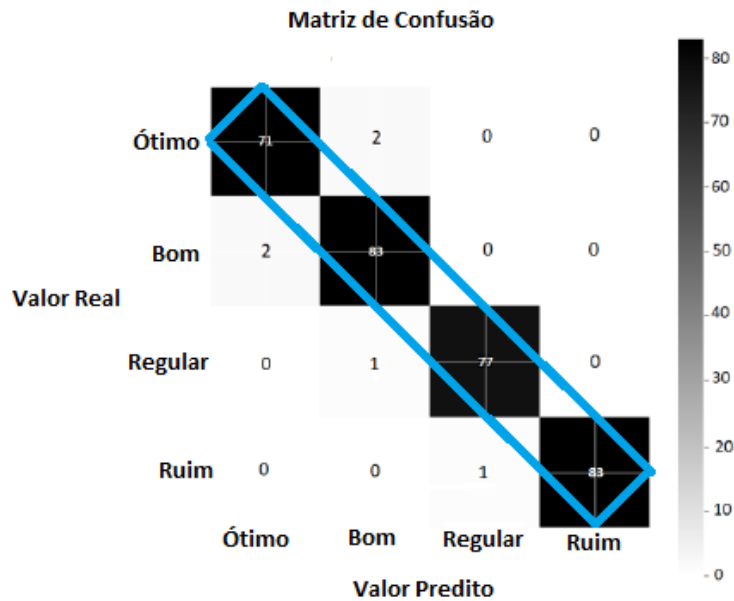


Figura 21: Acurácia a partir da matriz de confusão – Valores obtidos com o modelo refinado de GB – Condição 1 – banco de dados 2

Neste exemplo, a Acurácia para os dados apresentados pela Figura 21 é obtida por:

$$\text{Acurácia} = \frac{71 + 83 + 77 + 83}{73 + 86 + 78 + 83} = 98,12\%$$

## A.2 Precisão (*Precision*)

Sendo a métrica Precisão, tal qual o abordado nos trabalhos (“Deep Learning Book”, 2022), é dada pela Eq. (A.2).

$$\text{Precisão} = \frac{VP}{VP+FP} \tag{A.2}$$

Trata-se de uma métrica muito utilizada quando trabalhando-se com problemas onde uma das classes é mais importante que as demais. Exatamente o que essa dissertação se propõe a resolver, uma vez que são os valores classificados como “ótimos” àqueles que serão levados adiante para o correto alinhamento da linha de eixo.

Mais uma vez utilizando os conceitos de matriz de confusão, a precisão de cada uma das classes é obtida tal qual o exposto pela Figura 22, fazendo-se a soma dos

valores corretamente previstos para uma determinada classe e dividindo-a pelo número total de predições para a mesma classe.

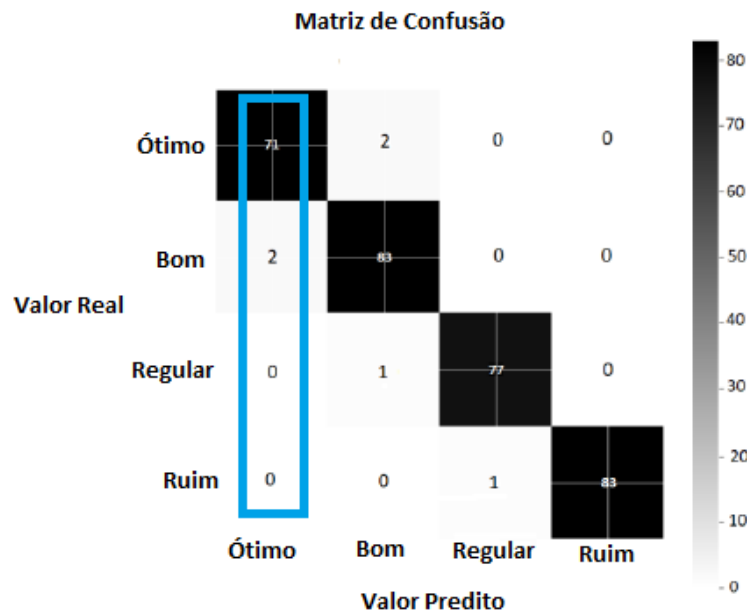


Figura 22: Precisão a partir da matriz de confusão da classe “Ótimo”

Na determinação da *Precisão* da classe “Ótimo”, por exemplo, tal qual o exposto pela Figura 22, basta, utilizando a Eq. (A.2), efetuar o seguinte cálculo:

$$\text{Precisão classe "Ótimo"} = \frac{71}{71+2} = 97,26\%$$

O cálculo da *Precisão* das demais classes se dá de forma análoga e, o cálculo da *Precisão média*, também se dá da forma exposta acima, ponderando-se as classes de acordo com as quantidades de amostras de cada uma delas.

### A.3 Revocação ou Sensibilidade (*Recall*)

Outra métrica de importância significativa é a *Revocação* ou *Sensibilidade*, sendo seu cálculo realizado de acordo com a Eq. (A.3) (MÜLLER, GUIDO, 2016, TAN, STEINBACH, *et al.*, 2006), como segue.

$$\text{Revocação} = \frac{VP}{VP+FN} \tag{A.3}$$

Essa métrica é de grande importância quando se deseja reduzir a quantidade de Falsos Negativos (FN). Um exemplo clássico de tal situação em problemas de predição, é o de diagnóstico de doenças, onde não deseja-se de forma alguma predizer que um determinado paciente, portador desta determinada doença, seja diagnosticado como saudável, o que pode leva-lo a ficar sem o devido tratamento.

Como nas métricas anteriores, o conceito de *Revocação* pode ser melhor compreendido a partir da matriz de confusão, conforme apresentado na Figura 23.

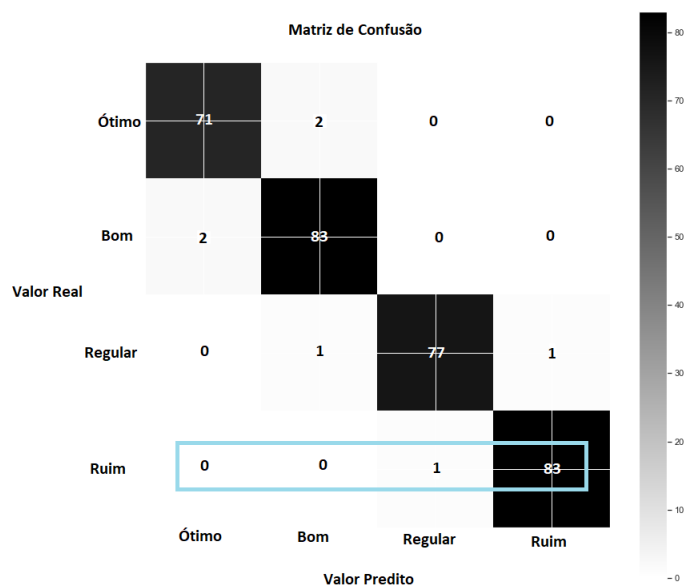


Figura 23: *Revocação* a partir da matriz de confusão da classe “Ruim”

Onde, para a classe “Ruim”, o modelo, nesse caso, obteve uma revocação de:

$$\text{Revocação da classe Ruim} = \frac{83}{83+1} = 98,81\%$$

O cálculo da *Revocação* das demais classes se dá de forma análoga e a *Revocação* média, também se dá de forma análoga à apresentada para a métrica de Precisão, ponderando-se as classes de acordo com as quantidades de amostras de cada uma delas.

No problema de alinhamento estudado nessa dissertação, por exemplo, falsos negativos implicam no descarte de conjuntos ótimos, por exemplo. Tal fato, apesar do desperdício de conjuntos que alinhem corretamente o sistema, de fato, não implica em maiores problemas para o sistema de eixo principal e de propulsão.

## A.4 F1-Score

A métrica do  $F1_{Score}$  refere-se à média harmônica das métricas Precisão e Revocação, sendo dada pela Eq. (A.4) (MÜLLER, GUIDO, 2016, TAN, STEINBACH, *et al.*, 2006).

$$F1_{Score} = \frac{2}{\frac{1}{Precisão} + \frac{1}{Revocação}} \quad (A.4)$$

Essa métrica costuma ser recomendada para classes desbalanceadas, conforme o observado no banco de dados número 3.

## Apêndice B – Índices Gini e Entropia

Estes índices, quando utilizados em problemas que envolvam árvores de decisão, buscam definir quais são as variáveis preditoras mais propensas a retornarem melhores resultados (ganhos de informação) no trabalho de ramificação das árvores e, por conseguinte, de predição (LANTZ, 2013, TAN, STEINBACH, *et al.*, 2006). Dessa forma, a partir destes índices, as variáveis que se sobressaem são alocadas mais acima quando do desenvolvimento das árvores. Este conceito serve também para os modelos derivados de árvores de decisão, tais como as utilizadas nesse estudo, *Extra-trees*, *Random Forest* e também ao *Gradient Boosting*.

### B.1 Índice Gini

O índice *Gini* é calculado conforme apresentado em (TAN, STEINBACH, *et al.*, 2006), através da seguinte equação:

$$Gini = 1 - \sum_j p_j^2 \quad (B.1)$$

onde:

$p_j$  = probabilidade da classe  $j$  em um nó da árvore.

### B.2 Índice Entropia

Já o índice Entropia, também abordado por (TAN, STEINBACH, *et al.*, 2006), segue a seguinte formulação.

$$Entropia = - \sum_j p_j \cdot \log_2 \cdot p_j \quad (B.2)$$

onde:

$p_j$  = probabilidade da classe  $j$  em um nó da árvore.

## Apêndice C – Funções de Ativação

As *funções de ativação* (também chamadas de *função de transferência*) utilizadas nas redes neurais profundas são, por definição, componentes matemáticos utilizados nas transformações, não-lineares, dos dados de entrada (*input data*), para a próxima camada da rede (“Deep Learning Book”, 2022), seja ela uma camada oculta ou de saída. Essas funções permitem que ao se variarem os pesos e *bias* da rede, os resultados (*outputs*) não sofram variações severas. Essas funções também definem se um determinado neurônio está ou não ativado. Busca-se, dessa forma, evitar que os resultados fujam do contexto do problema que se deseja resolver.

Existem várias funções de ativação com destaque para as duas funções que foram utilizadas nas redes estudadas nessa dissertação e são apresentadas a seguir.

### C.1 Função *Rectified Linear Unit* (*ReLU*)

A função *ReLU*, *Rectified Linear Unit*, é dada pela Eq. (C.1), onde  $x$  é o dado de entrada:

$$ReLU(x) = \max(0, x) \quad (C.1)$$

Trata-se de uma função de ativação não-linear, cuja principal vantagem é a da não ativação de todos os neurônios de uma só vez. Isto se deve ao fato de que entradas negativas são convertidas em zero e, portanto, tais neurônios acabam por não ser ativados (“Deep Learning Book”, 2022), vide Figura 24.

Sendo assim, foi esta a função de ativação utilizada entre as camadas de entrada e primeira camada intermediária, e também entre a 1ª intermediária e a segunda intermediária durante todos os modelos testados nesta dissertação.

A função *ReLU* é uma das mais utilizadas nas construções de redes neurais, embora não seja utilizada na camada de saída, onde, em problemas de classificação, costuma-se optar por funções de ativação que forneçam resultados em valores de porcentagem (“Deep Learning Book”, 2022).

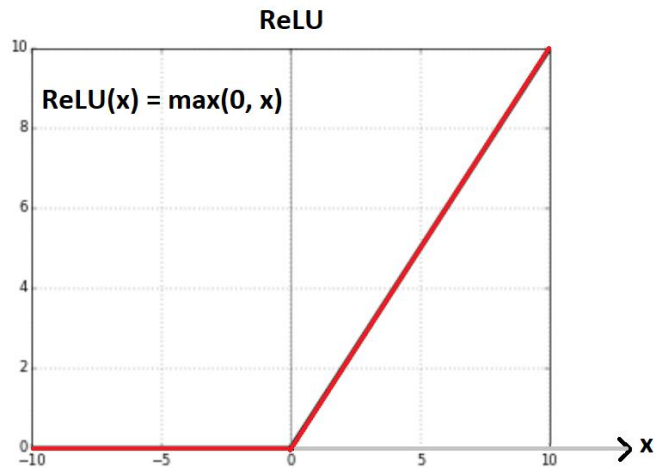


Figura 24: Função de ativação  $\text{ReLU}(x)$

## C.2 Função *Softmax*

A função *Softmax*, é dada pela Eq. (C.2), sendo  $x$  o dado de entrada:

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, \text{ para } j = 1, \dots, K \quad (\text{C.2})$$

onde:

$z_j$  = dados de entrada; e

$K$  = quantidade dos dados de entrada.

Trata-se de uma generalização da função *sigmoide* quando se trabalha com problemas não binários, (“Deep Learning Book”, 2022) este recurso matemático transforma os dados de saída em percentagens, cujo significado é a probabilidade de que a predição analisada ser pertencente àquela classe. Desta forma, a soma dos valores produzidos pela função *Softmax* será sempre igual a unidade.

As características supracitadas, intrínsecas a esta função, a tornam interessante de ser utilizada na camada de saída das configurações das redes neurais, onde de fato deseja-se identificar probabilidades de predição de uma amostra pertencer a uma determinada classe (“Deep Learning Book”, 2022). Esta foi a função de ativação utilizada na camada de saída dos modelos criados.

Ainda não há garantias matemáticas de quais funções de ativação são mais recomendadas para cada tipo de problema e bancos de dados analisados e, neste sentido, a opção pela utilização destas funções se deu de acordo com o sucesso empírico comprovado em problemas de natureza semelhante ao aqui estudado (leia-se problemas de classificação multiclass).