



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO TECNOLÓGICO DE JOINVILLE  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE SISTEMAS  
ELETÔNICOS

Patricia Mistura Klippel

**Utilização de IA em processos de otimização para o projeto do sistema de  
ancoragem de uma plataforma offshore**

DISSERTAÇÃO DE MESTRADO

Joinville  
2025

Patricia Mistura Klippel

**Utilização de IA em processos de otimização para o projeto do sistema de ancoragem de uma plataforma offshore**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Sistemas Eletrônicos da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Mestra em Engenharia de Sistemas Eletrônicos.

Orientador: Prof. Thiago Pontin Tancredi, Dr.

Joinville

2025

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.  
Dados inseridos pelo próprio autor.

Klippel, Patricia Mistura

Utilização de IA em processos de otimização para o projeto do sistema de ancoragem de uma plataforma offshore / Patricia Mistura Klippel ; orientador, Thiago Pontin Tancredi, 2025.

158 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Campus Joinville, Programa de Pós-Graduação em Engenharia de Sistemas Eletrônicos, Joinville, 2025.

Inclui referências.

1. Engenharia de Sistemas Eletrônicos. 2. Sistema de ancoragem. 3. Otimização. 4. Algoritmo genético. 5. Redes neurais artificiais. I. Tancredi, Thiago Pontin . II. Universidade Federal de Santa Catarina. Programa de Pós Graduação em Engenharia de Sistemas Eletrônicos. III. Título.

Patricia Mistura Klippel

**Utilização de IA em processos de otimização para o projeto do sistema de ancoragem de uma plataforma offshore**

O presente trabalho em nível de Mestrado foi avaliado e aprovado, em 04 de junho de 2025, pela banca examinadora composta pelos seguintes membros:

Prof. Thiago Pontin Tancredi, Dr.  
Universidade Federal de Santa Catarina

Prof. Bernardo Luis Rodrigues de Andrade, Dr.  
Universidade de São Paulo

Prof. Pablo Andretta Jaskowiak, Dr.  
Universidade Federal de Santa Catarina

Certificamos que esta é a versão original e final do trabalho de conclusão que foi julgado adequado para obtenção do título de Mestra em Engenharia de Sistemas Eletrônicos.

---

Coordenação do Programa de Pós-Graduação

---

Prof. Thiago Pontin Tancredi, Dr.  
Orientador

Joinville, 2025.

Dedico este trabalho, primeiramente, a Deus, por ser a base da minha vida.  
A minha mãe, Justina, e ao meu irmão, Patrick Cosme, pelo carinho e apoio  
incondicional, fundamentais para que eu chegasse até aqui.

## **AGRADECIMENTOS**

Primeiramente, agradeço a Deus, por estar presente em todos os momentos e por tornar tudo isso possível, me concedendo saúde e perseverança ao longo desta jornada acadêmica.

À minha mãe, Justina, cuja dedicação e amor incondicional foram fundamentais para que eu pudesse chegar até aqui. Ela sempre esteve ao meu lado, apoiando minhas decisões e oferecendo suporte em todos os momentos, independentemente dos desafios enfrentados. Ao meu irmão, Patrick Cosme, por sua ajuda incansável, por estar sempre comigo e por me proporcionar o apoio necessário em todas as situações. Meu profundo agradecimento a ambos pelo carinho, compreensão, incentivo e amor, que foram pilares essenciais nesta caminhada.

Ao meu orientador, professor Dr. Thiago Pontin Tancredi, pela generosidade em me acolher como orientanda, sempre me motivando, ensinando e aconselhando durante todos esses anos. Sua paciência e disposição em compartilhar seu tempo e conhecimento foram fundamentais para a realização deste trabalho. Espero um dia alcançar o nível de excelência profissional que o senhor representa para mim.

Aos professores do Programa de Pós-Graduação em Engenharia de Sistemas Eletrônicos (PPGESE), cujos ensinamentos e orientações contribuíram imensamente para o meu crescimento intelectual e desenvolvimento acadêmico, me ajudando a construir uma base sólida de conhecimento.

À Universidade Federal de Santa Catarina, por proporcionar um ambiente de aprendizado enriquecedor, novas experiências e oportunidades de desenvolvimento tanto pessoal quanto profissional.

Agradecimentos especiais à CAPES, cujo financiamento através da bolsa de pesquisa tornou este trabalho possível; à Petrobras S.A., pelo fornecimento de informações e apoio essencial ao desenvolvimento da pesquisa; e à Fundação de Ensino e Engenharia de Santa Catarina (FEESC), responsável pela gestão do financiamento que viabilizou este projeto. Também agradeço ao Laboratório de Simulação Naval, pelas instalações que ofereceram o ambiente adequado para o desenvolvimento deste trabalho.

Por fim, sou grata a todos aqueles que, direta ou indiretamente, contribuíram para a concretização deste trabalho.

*“A persistência é o caminho do êxito”.*

*(Charles Chaplin)*

## RESUMO

A exploração de petróleo em águas profundas (300-1500 metros) e ultraprofundas (>1500 metros) tem se intensificado nas últimas décadas, impulsionada pela descoberta das reservas do pré-sal no Brasil e pelo aumento global na demanda energética. Nessas regiões, a manutenção do posicionamento das plataformas depende diretamente do sistema de ancoragem, cujo projeto deve atender a critérios rigorosos relacionados ao deslocamento, tensões nas linhas e distribuição de carga. Nesse contexto, o projeto adequado e a análise detalhada desses sistemas são etapas fundamentais para garantir a segurança das operações sob condições ambientais adversas, como ondas, ventos e correntes marítimas. Esta dissertação apresenta uma metodologia estruturada em três etapas para otimizar o projeto de sistemas de ancoragem offshore. Na primeira etapa, realiza-se uma otimização multiobjetivo utilizando o algoritmo genético NSGA-II (Non-dominated Sorting Genetic Algorithm II), implementado no programa Synapse Offshore, programa desenvolvido pela Universidade Federal de Santa Catarina. Essa otimização utiliza cenários ambientais simulados pelos programas Dynasim, desenvolvido pela Petrobras, e Exmoor, programa resultante da colaboração entre a Universidade de São Paulo, a Universidade Federal de Santa Catarina e a Petrobras. O objetivo é identificar uma solução que minimize a porcentagem de deslocamento (offset) a partir do neutro, respeitando simultaneamente as restrições de tensão nas linhas, ângulo delta yaw neutro e carga nas âncoras. Na segunda etapa, desenvolve-se um modelo preditivo baseado em redes neurais artificiais, implementado em Python com o uso das bibliotecas TensorFlow/Keras para construção e treinamento das arquiteturas, e Scikeras em conjunto com Scikit-learn para validação cruzada (K-Fold) e ajuste de hiperparâmetros por meio do GridSearchCV. Os dados provenientes das simulações da etapa anterior são normalizados e organizados em conjuntos de treinamento, validação e teste. A qualidade das previsões é garantida por meio de validação cruzada e ajuste sistemático da rede neural. O modelo tem como função estimar os valores de deslocamento (offset) a partir do neutro, ângulo delta yaw neutro, tensões nas linhas e cargas nas âncoras. Na terceira etapa, o modelo preditivo substitui as simulações completas realizadas pelo Dynasim no processo de otimização. Essa substituição reduz significativamente o tempo de processamento das análises, possibilitando a avaliação rápida de um número maior de alternativas de projeto. Para garantir que a confiabilidade das soluções geradas esteja dentro dos limites técnicos estabelecidos, as previsões do modelo são validadas comparando-se seus resultados com simulações completas realizadas no Dynasim. Os resultados demonstram uma redução de aproximadamente 30% no tempo total das análises, mantendo-se a qualidade das previsões dentro de limites pré-estabelecidos. Além disso, o uso da abordagem proposta permite explorar mais soluções, facilitando a seleção de configurações adequadas para atender aos requisitos operacionais das plataformas offshore. A metodologia proposta contribui para maior eficiência e flexibilidade no desenvolvimento de sistemas de ancoragem e pode ser aplicada a outros problemas de engenharia naval e oceânica que envolvam simulações complexas e elevado custo computacional.

**Palavras-chave:** Sistema de ancoragem. Otimização. Algoritmo genético. Inteligência artificial. Redes neurais artificiais.

## ABSTRACT

Deepwater (300–1500 meters) and ultra-deepwater (> 1500 meters) oil exploration has intensified in recent decades, driven by the discovery of Brazil's pre-salt reserves and by the global rise in energy demand. In these regions, the maintenance of platform positioning depends directly on the mooring system, whose design must meet stringent criteria related to offset, line tensions, and load distribution. In this context, proper design and detailed analysis of these systems are fundamental steps to ensure operational safety under adverse environmental conditions such as waves, winds, and ocean currents. This dissertation presents a three-stage methodology for optimizing offshore mooring system design. In the first stage, a multi-objective optimization is carried out using the NSGA-II (Non-dominated Sorting Genetic Algorithm II) genetic algorithm, implemented in the Synapse Offshore software developed by the Federal University of Santa Catarina. That optimization employs environmental scenarios simulated by the Dynasim program (developed by Petrobras) and by Exmoor (the result of a collaboration between the University of São Paulo, the Federal University of Santa Catarina, and Petrobras). The objective is to identify a solution that minimizes percentage offset from the neutral point while simultaneously satisfying constraints on line tension, neutral delta-yaw angle, and anchor load. In the second stage, a predictive model based on artificial neural networks is developed in Python using TensorFlow/Keras for architecture construction and training, and Scikeras together with Scikit-learn for K-Fold cross-validation and hyperparameter tuning via GridSearchCV. Data from the previous stage's simulations are normalized and organized into training, validation, and test sets. Prediction quality is ensured through cross-validation and systematic network adjustment. The model estimates offset from neutral, neutral delta-yaw angle, line tensions, and anchor loads. In the third stage, the predictive model replaces the full Dynasim simulations within the optimization process. This substitution significantly reduces analysis processing time, allowing rapid evaluation of a greater number of design alternatives. To ensure that the reliability of generated solutions remains within established technical limits, the model's predictions are validated by comparing them with full Dynasim simulations. Results show an approximately 30 percent reduction in total analysis time while maintaining prediction quality within predefined bounds. Moreover, the proposed approach enables exploration of a broader solution space, facilitating the selection of configurations that meet offshore platform operational requirements. The methodology contributes to greater efficiency and flexibility in the development of mooring systems and can be applied to other naval and ocean engineering problems involving complex simulations and high computational cost.

**Keywords:** Mooring system. Optimization. Genetic algorithm. Artificial intelligence. Artificial neural networks.

## LISTA DE FIGURAS

Figura 1 – Unidades fixas e flutuantes .....	24
Figura 2 – Classificação tradicional das plataformas .....	24
Figura 3 – Bacia de Santos e Bacia de Campos .....	25
Figura 4 – Arranjo de um sistema de ancoragem.....	26
Figura 5 – Linha de ancoragem em catenária .....	29
Figura 6 – Linha de ancoragem taut leg .....	29
Figura 7 – Linha de ancoragem vertical .....	30
Figura 8 – Componentes de uma linha de ancoragem tradicional .....	31
Figura 9 – Raio de ancoragem .....	32
Figura 10 – Delta yaw .....	33
Figura 11 – Offset neutro .....	34
Figura 12 – Offset extremo.....	35
Figura 13 – Offset a partir do neutro .....	35
Figura 14 – Tensão em uma linha de ancoragem.....	36
Figura 15 – Carga aplicada nas âncoras.....	38
Figura 16 – Fluxograma geral de um algoritmo genético .....	46
Figura 17 – Fluxograma do ciclo típico de uma iteração do NSGA-II.....	49
Figura 18 – Exemplo de uma rede neural artificial .....	53
Figura 19 – Variáveis .....	59
Figura 20 – Objetivo .....	60
Figura 21 – Restrição .....	61
Figura 22 – DOE User e DOE Sobol .....	62
Figura 23 – Parte do modelo de otimização.....	63
Figura 24 – Metodologia utilizada no processo de otimização inicial .....	65
Figura 25 – Configuração do sistema de ancoragem.....	66
Figura 26 – Configuração da linha de ancoragem.....	67
Figura 27 – Comprimentos das linhas de ancoragem .....	68
Figura 28 – Variáveis no modelo de otimização.....	68
Figura 29 – Objetivo no modelo de otimização .....	69
Figura 30 – Restrições no modelo de otimização.....	71
Figura 31 – Solver (Dynasim) no modelo de otimização .....	72
Figura 32 – Parte do modelo de otimização.....	73

Figura 33 – Metodologia utilizada para elaboração do modelo de redes neurais.....	82
Figura 34 – Fluxograma geral do desenvolvimento do modelo preditivo .....	85
Figura 35 – Divisão dos dados em conjuntos de treinamento e teste .....	86
Figura 36 – Normalização com MinMaxScaler .....	87
Figura 37 – Validação cruzada .....	89
Figura 38 – Métricas estatísticas fundamentais .....	90
Figura 39 – Metodologia para a otimização com a integração do modelo preditivo ..	92
Figura 40 – Etapa inicial do modelo de otimização utilizando o modelo preditivo .....	93
Figura 41 – Variáveis utilizadas no modelo de otimização .....	94
Figura 42 – Restrições aplicadas no modelo de otimização .....	95
Figura 43 – Objetivo aplicado no modelo de otimização .....	96
Figura 44 – Fluxograma da primeira parte do código .....	97
Figura 45 – Fluxograma da segunda parte do código .....	98
Figura 46 – Modelo final no programa Synapse .....	99
Figura 47 – Resultados iniciais do processo de otimização .....	107
Figura 48 – Porcentagem de offset a partir do neutro em função das iterações .....	108
Figura 49 – Porcentagem de offset a partir do neutro em função das iterações .....	109
Figura 50 – Porcentagem de offset a partir do neutro em função das iterações .....	111
Figura 51 – Comparação entre valores reais e previstos para o offset .....	114
Figura 52 – Comparação entre valores reais e previstos para o delta yaw neutro ..	116
Figura 53 – Comparação entre valores reais e previstos para a tensão .....	117
Figura 54 – Comparação entre valores reais e previstos para a carga .....	119
Figura 55 – Offset % a partir do neutro estimado pelo modelo preditivo .....	125
Figura 56 – Tensão % nas linhas estimada pelo modelo preditivo.....	126
Figura 57– Tensão % nas linhas estimada pelo modelo preditivo.....	127
Figura 58 – Tensão % nas Linhas obtida pelo Synapse Offshore.....	127
Figura 59 – Delta yaw neutro (graus) estimado pelo modelo preditivo.....	128
Figura 60 – Delta yaw neutro (graus) obtido pelo Synapse Offshore .....	128
Figura 61 – % carga nas âncoras estimada pelo modelo preditivo .....	129
Figura 62 – % carga nas âncoras obtida pelo Synapse Offshore.....	129

## LISTA DE QUADROS

Quadro 1 – Alterações no comprimento do segmento junto ao fairlead .....	75
Quadro 2 – Alterações no comprimento do primeiro segmento de poliéster .....	76
Quadro 3 – Solução 12479.....	78
Quadro 4 – Ajustes nos limites do raio de ancoragem .....	78
Quadro 5 – Ajustes nos limites do comprimento do segmento junto ao fairlead .....	79
Quadro 6 – Ajustes nos limites do comprimento do primeiro segmento de poliéster.....	79
Quadro 7 – Alterações no comprimento do segmento junto ao fairlead .....	80
Quadro 8 – Alterações no comprimento do primeiro segmento de poliéster .....	81
Quadro 9 – Hiperparâmetros e topologias testadas no GridSearchCV .....	87
Quadro 10 – Limites e resoluções das variáveis .....	94
Quadro 11 – Novos limites e resoluções das variáveis .....	102
Quadro 12 – Resultados da primeira análise .....	108
Quadro 13 – Resultados da segunda análise .....	110
Quadro 14 – Resultados da terceira análise .....	130
Quadro 15 – Resultados da terceira análise .....	130

## LISTA DE ABREVIATURAS E SIGLAS

FPSO	<i>Floating Production Storage and Offloading</i> .....	17
IA	Inteligência Artificial.....	18
RNA	Redes Neurais Artificiais .....	18
TLP	<i>Tension Leg Platform</i> - Plataforma de Pernas Tensionadas .....	24
TDP	<i>Touchdown Point</i> - Ponto de Toque no Fundo.....	28
AG	Algoritmos Genéticos .....	45
NSGA	Algoritmo Genético de Ordenação Não Dominada .....	48
NSGA-II	Algoritmo Genético de Ordenação Não Dominada II .....	48
DOE	<i>Design of Experiments</i> .....	61
ISO	<i>International Organization for Standardization</i> .....	65

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>16</b>
1.1	OBJETIVOS .....	20
1.1.1	<b>Objetivo geral</b> .....	<b>20</b>
1.1.2	<b>Objetivos específicos</b> .....	<b>20</b>
1.2	ESTRUTURAÇÃO DO TRABALHO.....	21
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>23</b>
2.1	SISTEMA DE EXPLORAÇÃO OFFSHORE.....	23
2.2	SISTEMA DE ANCORAGEM.....	25
2.3	PROJETO E ANÁLISE DO SISTEMA DE ANCORAGEM .....	27
<b>2.3.1</b>	<b>Forças ambientais</b> .....	<b>27</b>
2.4	CONFIGURAÇÃO DAS LINHAS DE ANCORAGEM .....	28
<b>2.4.1</b>	<b>Linha de ancoragem em catenária</b> .....	<b>28</b>
<b>2.4.2</b>	<b>Linha de ancoragem de raio curto (taut leg)</b> .....	<b>29</b>
<b>2.4.3</b>	<b>Linha de ancoragem vertical</b> .....	<b>30</b>
2.5	ELEMENTOS PRINCIPAIS DAS LINHAS .....	30
2.6	CONCEITOS FUNDAMENTAIS.....	32
<b>2.6.1</b>	<b>Raio de ancoragem</b> .....	<b>32</b>
<b>2.6.2</b>	<b>Delta yaw</b> .....	<b>33</b>
<b>2.6.3</b>	<b>Offset</b> .....	<b>33</b>
<b>2.6.4</b>	<b>Tensão nas linhas</b> .....	<b>36</b>
<b>2.6.5</b>	<b>Carga nas âncoras</b> .....	<b>37</b>
2.7	FUNDAMENTOS DA OTIMIZAÇÃO .....	38
<b>2.7.1</b>	<b>Conceito de otimização</b> .....	<b>38</b>
<b>2.7.2</b>	<b>Tipos de problemas de otimização</b> .....	<b>39</b>
<b>2.7.3</b>	<b>Algoritmos de otimização tradicionais</b> .....	<b>41</b>
<b>2.7.4</b>	<b>Algoritmos de otimização heurística e metaheurísticas</b> .....	<b>42</b>
<b>2.7.5</b>	<b>Processo de otimização</b> .....	<b>43</b>
2.7.5.1	<i>Variáveis</i> .....	44
2.7.5.2	<i>Função objetivo</i> .....	44
2.7.5.3	<i>Restrições</i> .....	44
2.7.5.4	<i>Modelo matemático</i> .....	45

<b>2.7.6</b>	<b>Algoritmos genéticos</b>	<b>45</b>
2.7.6.1	<i>Algoritmo NSGA-II</i>	45
2.8	FUNDAMENTOS DA INTELIGÊNCIA ARTIFICIAL	49
<b>2.8.1</b>	<b>Redes neurais artificiais</b>	<b>52</b>
2.9	TRABALHOS RELACIONADOS	54
<b>3</b>	<b>METODOLOGIA</b>	<b>57</b>
3.1	FERRAMENTAS DE OTIMIZAÇÃO	57
<b>3.1.1</b>	<b>Synapse</b>	<b>57</b>
<b>3.1.2</b>	<b>Synapse Offshore</b>	<b>58</b>
3.2	ESTRUTURAÇÃO DO PROCESSO DE OTIMIZAÇÃO	58
<b>3.2.1</b>	<b>Seleção das variáveis</b>	<b>59</b>
<b>3.2.2</b>	<b>Função objetivo</b>	<b>60</b>
<b>3.2.3</b>	<b>Restrições</b>	<b>60</b>
<b>3.2.4</b>	<b>DOEs</b>	<b>61</b>
<b>3.2.5</b>	<b>Modelo de otimização</b>	<b>62</b>
3.3	ESTUDO DE CASO	64
<b>3.1.1</b>	<b>Processo de otimização</b>	<b>64</b>
3.1.1.1	<i>Primeira etapa do projeto do sistema de ancoragem</i>	65
3.1.1.2	<i>Segunda etapa do projeto do sistema de ancoragem</i>	74
3.1.1.3	<i>Terceira etapa do projeto do sistema de ancoragem</i>	77
<b>3.1.2</b>	<b>Aplicação de redes neurais no processo de otimização</b>	<b>82</b>
3.1.2.1	<i>Modelo preditivo utilizando redes neurais artificiais</i>	83
<b>3.1.3</b>	<b>Otimização do sistema de ancoragem utilizando o modelo preditivo</b>	<b>91</b>
3.1.3.1	<i>Construção do modelo no programa Synapse</i>	93
3.1.3.2	<i>Primeira etapa do processo de otimização com o modelo preditivo</i>	99
3.1.3.3	<i>Segunda etapa do processo de otimização com o modelo preditivo</i>	100
3.1.3.4	<i>Terceira etapa do processo de otimização com o modelo preditivo</i>	101
3.1.3.5	<i>Quarta etapa do processo de otimização com o modelo preditivo</i>	103
3.1.3.6	<i>Quinta etapa do processo de otimização com o modelo preditivo</i>	104
<b>4</b>	<b>RESULTADOS</b>	<b>106</b>
4.1	RESULTADOS DO PROCESSO DE OTIMIZAÇÃO	106
<b>4.1.1</b>	<b>Resultados da primeira etapa do processo de otimização</b>	<b>106</b>
<b>4.1.2</b>	<b>Resultados da segunda etapa do processo de otimização</b>	<b>109</b>
<b>4.1.3</b>	<b>Resultados da segunda etapa do processo de otimização</b>	<b>111</b>

4.2	RESULTADOS PARA O MODELO PREDITIVO.....	112
4.2.1	Resultados do modelo preditivo para offset a partir do neutro.....	113
4.2.2	Resultados do modelo preditivo para o delta yaw neutro.....	115
4.2.3	Resultados do modelo preditivo para tensão nas linhas .....	116
4.2.4	Resultados do modelo preditivo para carga nas âncoras.....	118
4.3	RESULTADOS DO PROCESSO DE OTIMIZAÇÃO UTILIZANDO O MODELO PREDITIVO COM REDES NEURAIAS ARTIFICIAIS .....	119
4.3.1	Primeira etapa – Avaliação inicial das soluções com o modelo preditivo .....	120
4.3.2	Segunda etapa – Ajuste fino do modelo preditivo e nova avaliação das soluções.....	121
4.3.3	Terceira etapa – Avaliação das soluções com restrições revisadas..	122
4.3.4	Quarta etapa – Novo ajuste com ampliação do conjunto de dados ...	123
4.3.5	Quinta etapa – Ajuste final e identificação da solução ótima .....	124
5	<b>CONCLUSÃO.....</b>	<b>133</b>
5.1	TRABALHOS FUTUROS .....	134
	<b>REFERÊNCIAS.....</b>	<b>135</b>
	<b>APÊNDICE A - Modelo Preditivo (Offset % a partir do neutro).....</b>	<b>149</b>
	<b>APÊNDICE B - Primeira parte do código aplicado no Synapse.....</b>	<b>154</b>
	<b>APÊNDICE C - Segunda parte do código aplicado no Synapse.....</b>	<b>156</b>

## 1 INTRODUÇÃO

O setor de petróleo e gás responde por uma parcela expressiva dos investimentos na economia brasileira devido ao seu caráter intensivo em capital, destacando-se especialmente após a descoberta das reservas do pré-sal na década de 2000 (Mendes; Teixeira; Rocio, 2018). Essa região apresenta petróleo de elevada qualidade e campos produtivos, colocando o Brasil em posição relevante no cenário global da exploração offshore (Riceto; Silva, 2021).

A exploração offshore desempenha papel estratégico na economia nacional, contribuindo diretamente para a produção brasileira de petróleo e gás. Em resposta a essa relevância, as tecnologias e ferramentas aplicadas aos sistemas de ancoragem têm passado por constantes atualizações, visando garantir o atendimento das demandas energéticas nacionais.

Para garantir a eficácia e segurança do sistema de ancoragem, a seleção de materiais e equipamentos deve considerar parâmetros técnicos como a profundidade local, as dimensões e peso da plataforma, bem como fatores ambientais específicos, incluindo correntes marítimas, ondas e ventos (Amaral, 2020). Além disso, é necessário realizar avaliações detalhadas para assegurar que o sistema suporte as condições previstas para a região.

O sistema de ancoragem é responsável pela manutenção da posição das plataformas e pela segurança das operações associadas (Chaves, 2020). De forma geral, esses sistemas são compostos por elementos como âncoras, cabos, fibras sintéticas, amarras e conectores, que trabalham em conjunto para conectar a estrutura flutuante ao fundo do mar (Ceolato, 2019). Esses componentes exercem função estrutural essencial no posicionamento da unidade.

Existem diferentes configurações de sistemas de ancoragem, que variam conforme as condições ambientais locais e os requisitos específicos de cada plataforma (Muniz, 2020). Entre as configurações mais utilizadas estão o sistema em catenária, em que a linha de ancoragem forma uma curva característica e permanece parcialmente apoiada sobre o fundo marinho; o sistema taut leg, caracterizado pelo tensionamento das linhas com ângulos reduzidos em relação à horizontal; e o sistema vertical, que utiliza tendões quase perpendiculares ao leito marinho para fixar a plataforma na posição desejada (Ferreira, 2016).

De acordo com Silva (2014), aspectos operacionais e profundidade do solo marinho determinam o tipo de plataforma (fixa<sup>1</sup> ou flutuante<sup>2</sup>) e a configuração mais adequada do sistema de posicionamento. No Brasil, plataformas semissubmersíveis e navios FPSO (Floating Production, Storage and Offloading) são os tipos mais comumente empregados na exploração offshore (Neves, 2015).

A exploração offshore envolve desafios e riscos inerentes à atividade, como potenciais acidentes ambientais e necessidades frequentes de investimentos em infraestrutura e tecnologia (Viglio; Giulio; Ferreira, 2017). Por esse motivo, o desenvolvimento das atividades offshore deve ser conduzido com responsabilidade, considerando seus impactos ambientais e sociais (Nascimento et al., 2021).

É justamente por garantir a integridade estrutural e a segurança operacional da plataforma frente às forças ambientais que o sistema de ancoragem constitui um componente essencial em projetos offshore. Rampazzo (2011) destaca que deslocamentos excessivos das unidades flutuantes podem prejudicar a integridade dos dutos de produção e a vida útil dos componentes associados, elevando o risco de vazamentos, com consequências tanto para a operação quanto para o meio ambiente ao redor da plataforma. Desse modo, o projeto adequado do sistema de ancoragem torna-se importante para minimizar esses riscos e garantir operações seguras e sustentáveis.

O projeto do sistema de ancoragem deve considerar cuidadosamente as condições ambientais do local onde a plataforma será instalada, incluindo variáveis como ondas, correntes marítimas e ventos. Além disso, é necessário definir parâmetros técnicos importantes, como o número de linhas de ancoragem, sua disposição ao redor da plataforma e as características estruturais e mecânicas de cada linha, buscando sempre minimizar o deslocamento da unidade.

A complexidade associada ao dimensionamento dessas configurações pode limitar a exploração detalhada do espaço de soluções possíveis, fazendo com que, frequentemente, seja adotada uma das primeiras soluções que atendam aos requisitos operacionais estabelecidos. Contudo, uma seleção criteriosa da

---

<sup>1</sup> Plataformas fixas são estruturas rígidas apoiadas no fundo marinho, usadas tipicamente até 300 m de profundidade.

<sup>2</sup> Plataformas flutuantes são unidades de casco flutuante ancoradas por linhas, adequadas para águas profundas e ultraprofundas (>300 m).

configuração do sistema é fundamental, pois o custo dos sistemas de ancoragem pode representar uma parcela significativa do custo total da plataforma.

Além da análise do deslocamento da plataforma, outros fatores técnicos também influenciam diretamente o projeto. Entre eles destacam-se o peso total dos componentes utilizados, o ângulo das linhas em relação à plataforma e o raio de ancoragem<sup>3</sup> adotado. Esses aspectos são avaliados criteriosamente, uma vez que estão diretamente associados à eficiência operacional, segurança estrutural e viabilidade econômica do sistema de ancoragem.

A utilização de técnicas baseadas em inteligência artificial (IA) tem sido cada vez mais comum na área de engenharia naval e offshore, particularmente no projeto e otimização de sistemas complexos, como os sistemas de ancoragem de plataformas offshore. Dentre essas técnicas destacam-se as redes neurais artificiais (RNAs), ferramentas capazes de construir modelos preditivos precisos e computacionalmente eficientes (Russell & Norvig, 2021). Esses modelos são capazes de estimar variáveis importantes, como deslocamentos da plataforma, tensões nas linhas e cargas aplicadas nas âncoras, com base em um conjunto previamente obtido de dados simulados.

No contexto do projeto de sistemas de ancoragem, as RNAs permitem substituir parcialmente a necessidade de realizar simulações dinâmicas completas em programas especializados, reduzindo significativamente o tempo de processamento necessário para avaliar diferentes configurações. O treinamento desses modelos é feito com um conjunto representativo de simulações, possibilitando ao modelo neural aprender e generalizar padrões existentes entre os parâmetros de entrada do sistema (como características geométricas, propriedades mecânicas e condições ambientais) e as respostas desejadas do sistema (como deslocamento (offset), ângulo delta yaw, tensões e cargas nas âncoras) (Yee; Mohamed; Montasir, 2021).

Um modelo preditivo bem desenvolvido possibilita que diversas soluções possam ser analisadas rapidamente, proporcionando uma exploração mais ampla do espaço de projeto em menos tempo do que seria possível com métodos tradicionais de simulação. Essa abordagem tem como principal vantagem permitir maior

---

<sup>3</sup> Raio de ancoragem é um parâmetro fundamental no sistema de ancoragem de plataformas, sendo definido como a distância horizontal, medida no solo marinho, entre o ponto de amarração na plataforma (fairlead) e o TDP (ponto de toque no fundo) (Nazário, 2015).

eficiência no processo de otimização do projeto, mantendo resultados com precisão próxima às simulações completas (Nascimento, 2023).

Diante da complexidade associada ao dimensionamento e da relevância operacional do sistema de ancoragem, esta dissertação propõe uma metodologia estruturada em três etapas que integra técnicas avançadas de otimização e inteligência artificial.

Primeiramente, realiza-se uma otimização multiobjetivo com o uso de algoritmos genéticos NSGA-II (Non-dominated Sorting Genetic Algorithm II), utilizando o software Synapse Offshore, desenvolvido pela Universidade Federal de Santa Catarina, apoiado por simulações dinâmicas nos programas Dynasim, desenvolvido pela Petrobras, e Exmoor, resultante da colaboração entre a Universidade de São Paulo, a Universidade Federal de Santa Catarina e a Petrobras.

Em seguida, na segunda etapa, os resultados das simulações iniciais serviram de base para o desenvolvimento e treinamento de redes neurais artificiais em Python, utilizando principalmente as bibliotecas TensorFlow/Keras para a construção e o treino das arquiteturas, e Scikeras, em conjunto com o Scikit-learn, para a validação cruzada (K-Fold) e o ajuste de hiperparâmetros via GridSearchCV. Essa estratégia visa garantir a robustez e a confiabilidade das previsões geradas para novas configurações do sistema.

Finalmente, na terceira etapa, o modelo preditivo desenvolvido é incorporado ao processo de otimização, substituindo parcialmente as simulações completas no solver dinâmico. Essa integração permite avaliações rápidas das alternativas, reduzindo significativamente o tempo total das análises e possibilitando que um número maior de soluções seja considerado.

Assim o objetivo é apresentar uma metodologia estruturada que integra técnicas avançadas de otimização e inteligência artificial para o projeto de sistemas de ancoragem offshore. Ao utilizar algoritmos evolutivos e modelos preditivos baseados em redes neurais artificiais, busca-se reduzir significativamente o tempo das análises, mantendo ou melhorando a qualidade e a diversidade das soluções avaliadas. Com isso, pretende-se oferecer uma contribuição prática para o desenvolvimento de sistemas de ancoragem, viabilizando um projeto mais eficiente e flexível, com potencial aplicação em diversos problemas semelhantes da engenharia naval e oceânica.

## 1.1 OBJETIVOS

Com o intuito de resolver a problemática relacionada à otimização e análise do sistema de ancoragem de uma plataforma offshore, esta dissertação estabelece os objetivos descritos nesta seção do texto.

### 1.1.1 Objetivo geral

Desenvolver uma metodologia integrada e estruturada em três etapas para o projeto e análise de sistemas de ancoragem de uma plataforma offshore, combinando técnicas de otimização com o uso de algoritmos genéticos e modelagem preditiva baseada em redes neurais artificiais. O objetivo é obter uma solução otimizada para o sistema de ancoragem, capaz de atender aos critérios técnicos de desempenho sob diferentes condições ambientais, reduzindo significativamente o tempo de análise por meio da substituição parcial de simulações completas. Busca-se, assim, aprimorar a eficiência do processo de projeto, sem comprometer a precisão dos resultados.

### 1.1.2 Objetivos específicos

No intuito de alcançar o objetivo geral, foram elencados os seguintes objetivos específicos:

- Realizar uma revisão bibliográfica técnica sobre sistemas de ancoragem offshore, algoritmos genéticos e redes neurais artificiais aplicadas a problemas de engenharia.
- Executar a modelagem e otimização do sistema de ancoragem de uma plataforma offshore utilizando o algoritmo genético NSGA-II no software Synapse Offshore, com suporte das simulações nos programas Dynasim e Exmoor.
- Desenvolver um modelo preditivo baseado em redes neurais artificiais, treinado com os dados obtidos na etapa de otimização, capaz de estimar as

variáveis de saída do sistema (offset a partir do neutro, delta yaw neutro, tensão nas linhas e carga nas âncoras).

- Integrar o modelo preditivo ao processo de otimização, substituindo parcialmente as simulações completas, com o objetivo de reduzir o tempo computacional das análises.
- Validar a solução final encontrada, comparando os resultados estimados pelo modelo preditivo com os resultados obtidos nas simulações completas no programa Dynasim.
- Avaliar o desempenho da metodologia proposta, verificando a acurácia das previsões, a redução no tempo de análise e os benefícios da integração entre técnicas de otimização e inteligência artificial no projeto de sistemas de ancoragem.

## 1.2 ESTRUTURAÇÃO DO TRABALHO

Este trabalho está organizado em cinco capítulos, incluindo esta introdução. No Capítulo 2 é apresentada a fundamentação teórica necessária para o desenvolvimento da pesquisa, abordando os principais conceitos relacionados aos sistemas de ancoragem offshore, suas configurações e componentes, bem como os fundamentos teóricos de otimização, algoritmos genéticos, inteligência artificial e redes neurais artificiais aplicadas ao contexto da engenharia. Esses conceitos fornecem o embasamento técnico para a compreensão da metodologia proposta.

No Capítulo 3, descreve-se a metodologia adotada, estruturada em três etapas principais. A primeira consiste na otimização do sistema de ancoragem por meio do algoritmo genético e simulações do comportamento dinâmico do sistema. A segunda etapa refere-se ao desenvolvimento de modelos preditivos com redes neurais artificiais, a partir dos dados obtidos nas simulações anteriores. A terceira etapa compreende a integração do modelo preditivo ao processo de otimização, substituindo parcialmente as simulações completas com o intuito de reduzir o tempo computacional. Neste capítulo, também são detalhados as ferramentas utilizadas, os parâmetros adotados e os procedimentos de implementação.

O Capítulo 4 apresenta os resultados obtidos nas três etapas da metodologia, com análise detalhada da solução otimizada, da acurácia dos modelos preditivos e da comparação entre os resultados estimados e os obtidos via

simulações completas. A discussão dos resultados é conduzida com base nos objetivos estabelecidos, evidenciando os ganhos em eficiência e desempenho.

Por fim, o Capítulo 5 reúne as conclusões da pesquisa, destacando as contribuições da metodologia proposta, os principais resultados alcançados e a forma como os objetivos foram atendidos. Também são discutidas as limitações do estudo e são sugeridas direções para trabalhos futuros, com ênfase na aplicação da abordagem desenvolvida em outros problemas de engenharia naval e oceânica que envolvam modelagem complexa e alto custo computacional.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, são apresentados os fundamentos teóricos que sustentam o desenvolvimento realizado. Inicialmente, discute-se o conceito de sistemas de ancoragem offshore, abordando os aspectos relacionados ao projeto, às configurações e aos principais elementos que os compõem. Em seguida, são introduzidos os conceitos fundamentais de otimização e de inteligência artificial, destacando o uso de algoritmos genéticos e redes neurais artificiais.

### 2.1 SISTEMA DE EXPLORAÇÃO OFFSHORE


O sistema de exploração offshore pode ser entendido como um conjunto de processos e tecnologias aplicados para a extração de petróleo e gás natural de reservas submarinas. Segundo (Silva, 2014), as plataformas podem ser divididas em dois grupos principais (unidades fixas e flutuantes), e sua utilização depende de determinados fatores, como aspectos técnicos, finalidade da operação, profundidade e localização da lâmina d'água, além de considerar diferentes fatores econômicos.

Conforme apontado por Junior (2019), a exploração de reservas petrolíferas em águas rasas tem tradicionalmente utilizado plataformas fixas, sendo usualmente limitadas a lâminas d'água inferiores a 300 metros de profundidade. Contudo, à medida que o setor petrolífero avança, na exploração em águas profundas (300-1500 metros) e ultraprofundas (>1500 metros), torna-se inviável o uso dessas estruturas convencionais (Bico, 2013).

Nesse sentido, Chaves (2020) pontua que, em cenários com profundidades superiores a 300 metros, torna-se imperativo o emprego de estruturas capazes de suportar as consideráveis exigências impostas pelo meio ambiente. No entanto, a implementação dessas estruturas enfrenta desafios significativos, incluindo custos substanciais e complexidades técnicas consideráveis. A Figura 1 apresenta exemplos representativos dessas unidades.

Essa expansão adiciona detalhes sobre o uso tradicional de plataformas em águas rasas, ressaltando os desafios crescentes enfrentados à medida que a exploração se direciona para águas mais profundas, ampliando o entendimento sobre a complexidade do cenário.

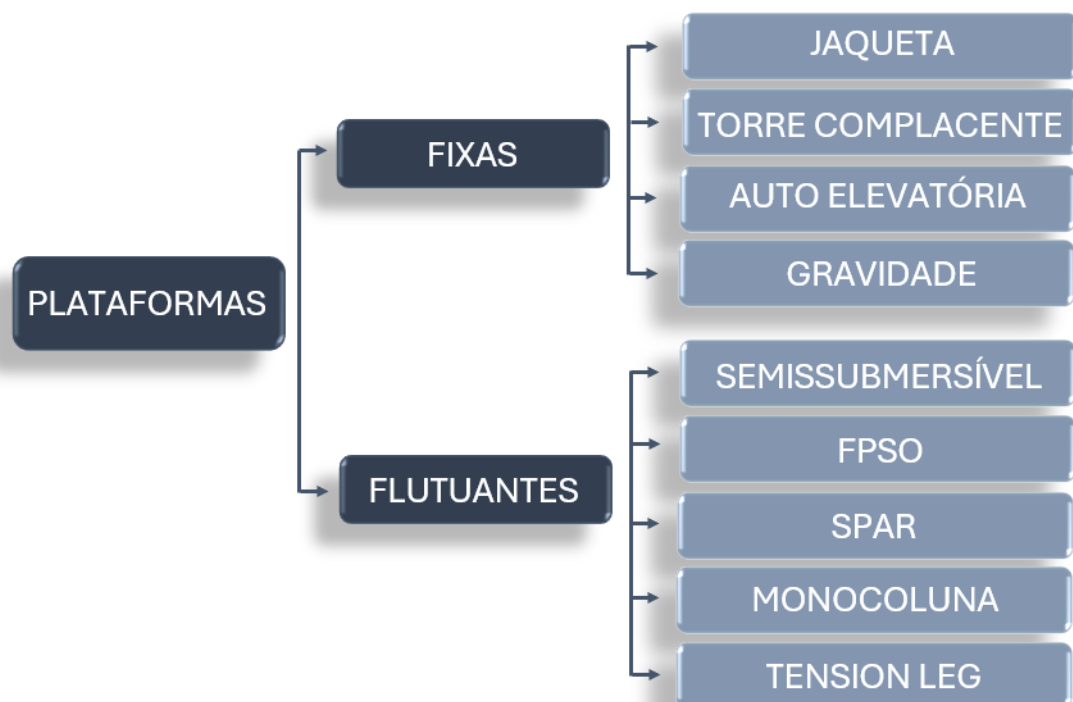
Figura 1 – Unidades fixas e flutuantes.



Fonte: Adaptado de Rui et al. (2024).

A Figura 2 apresenta a classificação em unidades fixas e flutuantes. As unidades fixas compreendem estruturas como plataformas do tipo jaqueta, torres complacentes, auto elevatórias e de gravidade (Amorim, 2010). No que se refere às unidades flutuantes, destacam-se as plataformas semissubmersíveis, os FPSOs (Floating Production, Storage and Offloading), as plataformas do tipo Spar, as plataformas monocoluna e as TLPs (Tension Leg Platforms) (Neves, 2015).

Figura 2 – Classificação tradicional das plataformas.



Fonte: Elaborado pela autora (2024).

Seguindo a tendência mundial, a produção de petróleo e gás nos campos brasileiros tem se concentrado na exploração de áreas profundas, situadas a mais de 100 quilômetros da costa, como as bacias de Santos e de Campos (Petrobras, 2025). Esse cenário tem impulsionado o desenvolvimento tecnológico e científico da indústria do petróleo no Brasil e internacionalmente. A Figura 3 apresenta a localização das bacias de Santos e Campos.

Figura 3 – Bacia de Santos e Bacia de Campos.



Fonte: Adaptado de Riccomini (2012).

De acordo com a Petrobras (2025), as bacias de Campos e Santos seguem como as principais regiões produtoras de petróleo no Brasil. A Bacia de Campos, pioneira na exploração em lâminas d'água elevadas, permanece como um polo relevante para a aplicação de novas tecnologias. E a Bacia de Santos, que abriga os principais campos do pré-sal, apresenta destaque no volume de produção e no uso intensivo de unidades FPSOs. Segundo a Petrobras, mais de vinte plataformas operam atualmente no pré-sal, e a empresa prevê a instalação de 15 novas unidades até 2030, sendo nove já contratadas.

## 2.2 SISTEMA DE ANCORAGEM

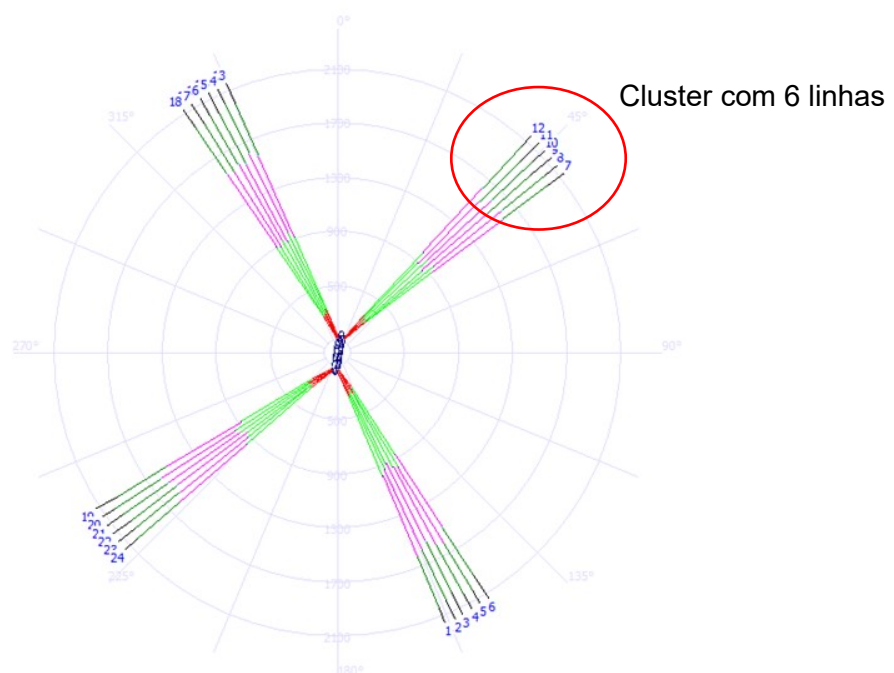
Embora a tecnologia de posicionamento dinâmico tenha avançado significativamente nos últimos anos, as linhas de ancoragem fixadas ao fundo por meio de âncoras continuam sendo o método mais utilizado para manter o posicionamento de unidades flutuantes para produção de petróleo em alto mar (Junior, 2019).

O sistema de ancoragem tem como objetivo manter o movimento da unidade flutuante dentro dos limites de deslocamento definidos pelo projeto, mesmo quando sujeita às mais diversas solicitações ambientais (Vieira, 2022). Nesse sentido, o sistema funciona exercendo forças restauradoras que mantêm a unidade na posição e garantem a segurança e a viabilidade das atividades exploratórias.

Considerando a complexidade e variabilidade inerentes aos projetos offshore, é essencial reconhecer que as linhas de ancoragem podem assumir configurações espaciais distintas e pontos de acoplamento específicos. De acordo com o tipo de fundação, profundidade do mar, tipo de operação, custo de implantação, e outros fatores relevantes, as configurações das linhas podem ser adaptadas para atender às exigências específicas de cada cenário (Rivai, 2016).

Na Figura 4, é apresentado um exemplo prático dessa diversidade, com um arranjo típico do sistema de ancoragem de uma plataforma. Neste caso, a plataforma está ancorada usando vinte e quatro linhas, agrupadas em quatro clusters. Essa disposição estratégica reflete a necessidade de distribuir a carga de forma equitativa e otimizar a estabilidade da unidade flutuante, evidenciando como as escolhas de configuração das linhas de ancoragem são fundamentais para garantir o desempenho adequado do sistema em diferentes contextos operacionais e ambientais.

Figura 4 – Arranjo de um sistema ancoragem.



Fonte: Adaptado do programa Exmoor (2024).

## 2.3 PROJETO E ANÁLISE DO SISTEMA DE ANCORAGEM

O deslocamento máximo da unidade, a tensão máxima admissível nas linhas, as cargas máximas transmitidas nas âncoras e o comprimento mínimo das linhas são apenas algumas das características que devem ser consideradas ao se projetar um sistema de ancoragem para uma unidade flutuante (Kun et al., 2021). A determinação dessas variáveis e a verificação dos critérios e requisitos estabelecidos são etapas fundamentais do processo de projeto (Amaral, 2020).

O cálculo das tensões máximas nas linhas, decorrentes dos movimentos e deslocamentos da unidade quando sujeita a forças ambientais como ondas, ventos e correntes, são elementos cruciais no dimensionamento do sistema (Guo et al., 2014). Pois, cabe ao sistema de ancoragem preservar a posição da embarcação, pois esses movimentos podem comprometer a integridade da plataforma e prejudicar os risers (Martins, 2011).

Desse modo, para garantir a segurança do sistema de ancoragem, é necessário calcular a intensidade das forças ambientais ainda nas fases iniciais do projeto. Por fim, para que um sistema seja instalado com segurança, deve-se confirmar que os valores estimados estão de acordo com os requisitos impostos para o projeto (Krugerud, 2016).

### 2.3.1 Forças ambientais

As plataformas offshore estão sujeitas a uma variedade de fatores ambientais, como ventos, ondas e correntes, que podem induzir deslocamento na unidade (Neves, 2015). Segundo Barboza (2022), é vital avaliar as muitas combinações potenciais de esforços e determinar a carga crítica para cada estrutura offshore, a fim de construir um sistema de ancoragem que possa absorver tais forças. Além disso, cada tipo de unidade apresenta características específicas que exigem soluções de ancoragem adaptadas para cada cenário operacional.

Existem dois tipos de forças que influenciam os sistemas: estática e dinâmica. As forças estáticas referem-se às cargas constantes e ininterruptas que atuam na estrutura, mesmo na ausência de movimento aparente (Melo, 2010). O peso próprio da unidade, as tensões nas linhas de ancoragem e as pressões hidrostáticas são exemplos de forças estáticas. Estas forças estabelecem a base de

sustentação e equilíbrio, sendo fundamentais para a estabilidade a longo prazo da unidade (Barboza, 2022). Por outro lado, as forças dinâmicas são aquelas que variam com o tempo e têm o potencial de induzir movimento na unidade flutuante, os ventos, ondas e correntes marítimas representam exemplos típicos de forças dinâmicas (Melo, 2010).

Esse contexto desafiante destaca a necessidade de engenharia precisa, inovação tecnológica e rigorosos protocolos de segurança para garantir a robustez dessas estruturas em ambientes marinhos desafiadores. A compreensão e adaptação contínuas às forças ambientais não apenas asseguram a estabilidade e eficiência operacional, mas também refletem o compromisso da indústria offshore com práticas sustentáveis e responsáveis.

## 2.4 CONFIGURAÇÃO DAS LINHAS DE ANCORAGEM

As diferentes disposições espaciais definem as configurações de linhas utilizadas em projetos de ancoragem (Vieira, 2022), podendo incluir sistemas formados por linhas em catenária (configuração convencional), linhas retesadas (taut-leg) e sistemas de ancoragem vertical (Rivai, 2016).

Essas configurações têm como característica comum o dever de fornecer o nível de restauração necessário para manter as unidades flutuantes dentro dos limites máximos de deslocamento estabelecidos em projeto, assegurando a estabilidade posicional da plataforma (Rodrigues, 2011).


### 2.4.1 Linha de ancoragem em catenária

Segundo Chaves (2020), a ancoragem em catenária, também denominada ancoragem convencional, caracteriza-se pelo uso de linhas suspensas pelas extremidades e sujeitas ao peso próprio. Esse tipo de arranjo é amplamente empregado por navios FPSO e plataformas semissubmersíveis (Vieira, 2022). Em sistemas de ancoragem em catenária, o ponto de conexão da linha com a unidade flutuante é denominado ponto de amarração (fairlead), enquanto o ponto de contato com o fundo marinho é conhecido como TDP (Touch Down Point) (Nazário, 2015).

O grande raio de ancoragem utilizado nesse sistema, associado ao atrito produzido pelo trecho da linha apoiado no solo marinho, é responsável por absorver

a maior parte das solicitações decorrentes dos esforços ambientais (Amaral, 2020). Além disso, essa configuração permite maior liberdade de movimento da unidade flutuante sem gerar esforços excessivos nas âncoras (Chaves, 2020). Um exemplo de plataforma ancorada por duas linhas em catenária é apresentado na Figura 5.

Figura 5 – Linha de ancoragem em catenária.




Fonte: Adaptado de Amaral (2020).

#### 2.4.2 Linha de ancoragem de raio curto (taut leg)

Em comparação com a ancoragem catenária, a ancoragem taut leg apresenta um menor comprimento e uma menor projeção horizontal das linhas para o mesmo comprimento de lâmina d'água. De acordo com Jacovazzo (2006), nesse arranjo, além do peso próprio, as linhas são tensionadas para permanecer retas, operando com ângulos de lançamento tipicamente entre  $40^\circ$  e  $45^\circ$  em relação à vertical. A Figura 6 apresenta a configuração de uma linha de ancoragem do tipo taut-leg.

Figura 6 – Linha de ancoragem taut leg.



Fonte: Adaptado de Amaral (2020).

Esse arranjo confere ao sistema maior rigidez e, portanto, uma maior restrição ao movimento da estrutura flutuante (Vale, 2011). No entanto, as âncoras


utilizadas nesta situação devem ser capazes de suportar cargas maiores, em especial na direção vertical, pois a tração imposta às linhas também é transmitida diretamente para as âncoras. Adicionalmente, a maior carga vertical exigida para as âncoras inviabiliza o uso de âncoras convencionais, exigindo o desenvolvimento e a utilização de âncoras do tipo torpedo.

### 2.4.3 Linha de ancoragem vertical

A configuração de ancoragem vertical utiliza cabos dispostos na direção vertical, tracionados pelo empuxo gerado pela parte submersa da unidade flutuante. De acordo com Bico (2013), essa configuração é tão singular que deu origem a uma classe específica de plataformas offshore, denominadas TLPs (Tension Leg Platforms).

Nesse sistema, os cabos conferem elevada rigidez vertical e baixa rigidez horizontal à estrutura, resultando em uma componente horizontal da força de tração que atua para restaurar a posição da plataforma após deslocamentos (Amaral, 2020). Um exemplo de sistema de ancoragem vertical é apresentado na Figura 7.

Figura 7 – Linha de ancoragem vertical.



Fonte: Adaptado de Amaral (2020).

## 2.5 ELEMENTOS PRINCIPAIS DAS LINHAS


As linhas que conectam a plataforma ao fundo do mar constituem os principais elementos de um sistema de ancoragem. Conforme discutido anteriormente, essas linhas podem variar tanto em termos da configuração geométrica (catenária, taut-leg e vertical) quanto em relação aos materiais empregados em cada segmento.

Entre os principais componentes utilizados para esse fim, destacam-se os cabos de aço, conhecidos por sua resistência e durabilidade em ambientes marinhos. Esses cabos oferecem uma base sólida para garantir a estabilidade necessária, especialmente em condições adversas (Leal, 2016).

Além dos cabos de aço, os cabos de fibra sintética se destacam como uma alternativa leve e de alta resistência. Sua flexibilidade e capacidade de absorver choques tornam-se ideais para situações em que a mitigação de cargas dinâmicas é fundamental (Barboza, 2022). Por outro lado, as amarras, representadas por correntes de aço, oferecem uma abordagem tradicional e confiável para a ancoragem, contribuindo para a solidez do sistema (Ferreira, 2016).

A compreensão de um sistema de ancoragem requer a consideração não apenas dos materiais principais, mas também dos elementos complementares, tais como conectores, âncoras e apêndices, os quais atuam de forma integrada para a fixação eficiente da unidade flutuante (Silva, 2016). A Figura 8 apresenta uma ilustração dos principais componentes de um sistema de ancoragem.

Figura 8 – Componentes de uma linha de ancoragem tradicional.



Fonte: Adaptado de Vryhof Anchor (2013).

Conforme discutido por Silva (2011), a depender dos requisitos de desempenho estabelecidos para um sistema de ancoragem, podem ser utilizadas diversas soluções, as quais podem combinar diferentes quantidades de linhas, com segmentos formados pelos mais diferentes materiais, diâmetros e comprimentos.

## 2.6 CONCEITOS FUNDAMENTAIS

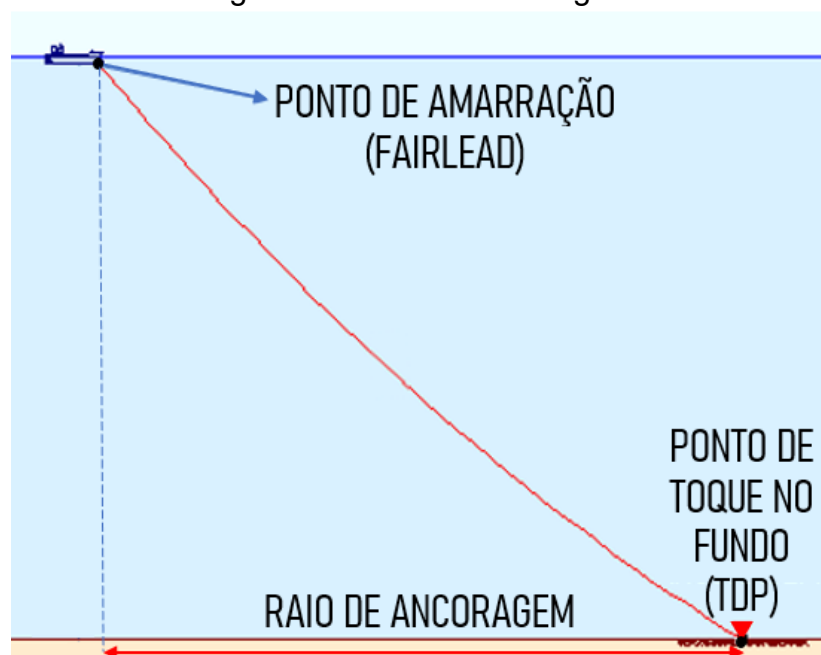
Na sequência, serão apresentados conceitos fundamentais que desempenham um papel essencial para o entendimento e otimização de sistemas de ancoragem. Tais informações fornecem uma base sólida de conhecimento, contribuindo para a abordagem eficiente de questões relacionadas à otimização de linhas de ancoragem em diversos contextos.

### 2.6.1 Raio de ancoragem

Conforme destacado por Nazário (2015), o raio de ancoragem é um parâmetro fundamental no sistema de ancoragem de plataformas offshore, sendo definido como a distância horizontal, medida no solo marinho, entre o ponto de amarração na plataforma (fairlead) e o TDP (ponto de toque no fundo).

A Figura 9 apresenta uma representação gráfica desse conceito, evidenciando a relação entre o ponto de amarração (fairlead) e o TDP. A determinação e o controle do raio de ancoragem são essenciais para o projeto e para a operação segura dos sistemas de ancoragem de unidades flutuantes.


Figura 9 – Raio de ancoragem.



Fonte: Elaborado pela autora (2024).

### 2.6.2 Delta yaw

O delta yaw, ou variação no ângulo de yaw, é uma medida que descreve a alteração no posicionamento angular de uma embarcação em relação ao seu eixo vertical (Tomera, 2015), conforme representação na Figura 10.



Fonte: Elaborado pela autora (2024).

O termo delta yaw neutro refere-se à mudança no ângulo de yaw entre a posição de projeto (condição meta) e a posição alcançada pela embarcação na ausência de esforços ambientais (condição neutra). Em outras palavras, é o ponto em que os efeitos dos movimentos da embarcação sobre o ângulo de yaw são minimizados, resultando em uma posição mais estável (lanagui, 2019).


No contexto dos projetos de ancoragem de plataformas offshore, é necessário estabelecer limites para o delta yaw neutro a fim de evitar a torção das linhas de ancoragem com os risers ou entre as próprias linhas, o que pode comprometer a integridade estrutural do sistema e representar riscos operacionais.

### 2.6.3 Offset

O offset pode ser definido como o deslocamento da unidade flutuante no plano da linha d'água. De acordo com Blanco (2013), o limite máximo admissível para o offset está diretamente relacionado aos parâmetros operacionais dos equipamentos interligados, como risers, linhas de ancoragem e módulos de perfuração. Para compreender de forma mais detalhada os conceitos relacionados

ao offset, considera-se inicialmente a posição meta, cuja representação gráfica encontra-se na Figura 11. Esse ponto é definido como a posição ideal para a plataforma, considerando uma série de parâmetros específicos do projeto. No contexto desta representação, esse ponto meta não apenas simboliza estabilidade, mas também incorpora considerações de eficiência operacional, segurança estrutural e alinhamento com os padrões e objetivos estabelecidos.

Figura 11 – Offset neutro.




Fonte: Elaborado pela autora (2024).

Após a instalação das linhas, especialmente os risers, observa-se que o sistema não atinge um equilíbrio perfeito, resultando em um movimento da plataforma. O ponto específico onde a plataforma se estabiliza é identificado como a posição neutra. A diferença entre a posição desejada (posição meta), e a posição neutra é denominada offset neutro. Para quantificar essa diferença em relação à profundidade, calcula-se a porcentagem de offset neutro, fornecendo uma medida precisa do deslocamento em relação ao objetivo original. Essa análise detalhada do offset neutro é importante para compreender como a plataforma irá operar.

No entanto, devido à influência constante de ventos, ondas e correntes, a plataforma se desloca em torno da posição neutra. O ponto de equilíbrio alcançado nessa condição é denominado de posição extrema, conforme representado na Figura 12. A distância entre a posição meta e a posição extrema é definida como offset extremo, cuja porcentagem é obtida pela divisão desse valor pela profundidade.


Figura 12 – Offset extremo.



Fonte: Elaborado pela autora (2024).

Por fim, o offset a partir do neutro corresponde à distância entre a posição neutra e a posição extrema, conforme representado na Figura 13. Ao dividir esse valor pela profundidade, obtém-se a porcentagem de offset a partir do neutro. Esta condição representa o cenário crítico a ser analisado, uma vez que é nesse estado que podem ocorrer modos de falha por ruptura ou fadiga dos risers e ou das linhas de ancoragem.

Figura 13 – Offset a partir do neutro.



Fonte: Elaborado pela autora (2024).


### 2.6.4 Tensão nas linhas

O projeto adequado do sistema de ancoragem é essencial para garantir que os deslocamentos e as tensões nas linhas permaneçam dentro dos limites de segurança estabelecidos para as operações (Bico, 2013). A definição apropriada desses parâmetros contribui diretamente para a preservação da integridade da unidade flutuante em condições marítimas adversas.

À medida que a profundidade do mar da área de exploração aumenta, naturalmente aumenta o comprimento suspenso dos cabos. No caso de linhas em catenária, ocorrem variações significativas na tensão ao longo da linha, conforme ela é esticada ou afrouxada (Bico, 2013). As variações dinâmicas de tensão resultam em forças de restauração não lineares, desempenhando papel relevante na capacidade da estrutura de resistir às forças aplicadas por ondas e ventos (Blanco, 2013).

A análise do perfil em catenária reforça a necessidade de compreender e otimizar a resposta do sistema de ancoragem frente às condições variáveis do ambiente marinho. A Figura 14 apresenta uma representação típica das tensões distribuídas ao longo de uma linha de ancoragem.

Figura 14 – Tensão em uma linha de ancoragem.



Fonte: Elaborado pela autora (2024).

Assim, as tensões nas linhas de ancoragem constituem um fator decisivo para a segurança e o controle dos deslocamentos das plataformas offshore, sendo determinante para a capacidade da unidade de resistir às forças ambientais atuantes no sistema. A correta previsão e monitoramento dessas tensões são etapas

fundamentais no desenvolvimento de projetos, especialmente em regiões de águas profundas e ultraprofundas.

### **2.6.5 Carga nas âncoras**

Estudos, como o realizado por Amaral e Costa (2004), indicam que as magnitudes das cargas nas âncoras apresentam uma relação linear em função das cargas atuantes no TDP (ponto de toque no fundo). Essa constatação é relevante, pois demonstra uma consistência no comportamento das forças aplicadas nas âncoras, independentemente da profundidade de cravação das estacas torpedo.


A compreensão desta relação linear tem implicações práticas significativas. Permite um dimensionamento mais preciso das âncoras, garantindo que elas possam suportar de maneira eficaz as cargas dinâmicas e estáticas, contribuindo assim para a estabilidade global das plataformas (Sampa, 2015). A correta definição das cargas atuantes é essencial para evitar o superdimensionamento, que acarreta aumento de custos, ou o subdimensionamento, que pode comprometer a segurança estrutural do sistema de ancoragem.

As cargas transmitidas às âncoras podem ser decompostas em componentes verticais e horizontais. As cargas verticais estão associadas ao peso da embarcação e às forças aplicadas verticalmente sobre o sistema, enquanto as cargas horizontais correspondem às forças de arrasto e aos esforços laterais gerados pelas ações ambientais (Pinto, 2023).

As cargas verticais influenciam diretamente a capacidade de cravação das âncoras, enquanto as cargas horizontais impactam a estabilidade lateral da unidade, exigindo soluções específicas de fixação dependendo do tipo de solo e profundidade. A Figura 15 apresenta uma representação esquemática da aplicação de cargas em uma âncora do tipo torpedo.

A análise adequada das cargas é fundamental para a prevenção de falhas, especialmente em situações em que as cargas atingem seus valores máximos (Salgado, 2008). Esse aspecto reforça a necessidade de adotar soluções de fixação específicas, como âncoras desenvolvidas para suportar elevadas cargas verticais e horizontais, assegurando a estabilidade do sistema de ancoragem em condições operacionais severas.

Figura 15 – Carga aplicada nas âncoras.



Fonte: Elaborado pela autora (2023).

## 2.7 FUNDAMENTOS DA OTIMIZAÇÃO

Com o avanço da tecnologia, diversas técnicas de otimização foram desenvolvidas com o propósito de identificar a melhor solução viável para um problema ou determinar os valores ideais para parâmetros de projeto (Martins, 2011). Em geral, essas técnicas visam maximizar ou minimizar características relevantes, como desempenho, custo ou confiabilidade (Cabral, 2016).

De acordo com Tancredi (2008), o termo “otimização” refere-se à busca sistemática, automática e dirigida da solução mais eficiente dentro de um conjunto de alternativas viáveis, respeitando as restrições técnicas, operacionais e econômicas previamente estabelecidas. Essa busca torna-se ainda mais estratégica em ambientes complexos e dinâmicos, como é o caso de sistemas offshore, onde pequenas melhorias podem representar ganhos expressivos.

Neste contexto, a seguir são apresentados os conceitos fundamentais de otimização, o funcionamento dos algoritmos genéticos e a metodologia adotada para a busca de soluções no projeto de sistemas de ancoragem offshore.

### 2.7.1 Conceito de otimização

A otimização é uma área da matemática aplicada que tem como objetivo encontrar a melhor solução possível para um problema dentro de um conjunto definido de alternativas, respeitando determinadas condições ou restrições. Essa

busca sistemática visa maximizar ou minimizar uma função objetivo, que representa um critério de desempenho, custo, eficiência, segurança ou outro indicador relevante para o problema em análise (Arora, 2011).

Do ponto de vista formal, um problema de otimização é geralmente expresso como a minimização (ou maximização) de uma função  $f(x)$ , sujeita a um conjunto de restrições  $g_i(x) \leq 0$  e  $h_j(x) = 0$ , onde  $x$  representa o vetor de variáveis de decisão (Nocedal; Wright, 2006). Essas variáveis são ajustadas pelo algoritmo de otimização de forma a satisfazer as restrições enquanto se busca o valor ótimo da função objetivo.

A relevância da otimização é amplamente reconhecida em diferentes ramos da engenharia, economia, logística, ciências aplicadas e, mais recentemente, em áreas interdisciplinares como ciência de dados e inteligência artificial. Em engenharia, por exemplo, problemas de projeto frequentemente envolvem a seleção de parâmetros ideais que otimizem peso, consumo energético, custo, velocidade ou confiabilidade, considerando limitações físicas e operacionais do sistema (Bazaraa, Sherali & Shetty, 2006).

Nesse contexto, a otimização tem se consolidado como uma abordagem indispensável para a engenharia moderna, especialmente em aplicações que envolvem sistemas complexos e de alto custo, como os encontrados no setor offshore. O uso de algoritmos de otimização permite explorar um vasto espaço de soluções possíveis, facilitando a identificação de configurações que atendam simultaneamente aos critérios de desempenho, segurança e viabilidade técnica (Arora, 2011).

### **2.7.2 Tipos de problemas de otimização**

Os problemas de otimização podem ser classificados de acordo com diferentes critérios, sendo os mais comuns: o número de funções objetivo, a natureza das variáveis de decisão e a presença ou ausência de restrições. Essa categorização é fundamental para a escolha da metodologia mais apropriada para a resolução do problema (Bazaraa, Sherali & Shetty, 2006). A identificação correta do tipo de problema permite selecionar algoritmos de busca mais eficientes e adaptar estratégias de resolução às características específicas do sistema analisado.

### *A. Otimização mono-objetivos*

Na otimização mono-objetivo, busca-se maximizar ou minimizar uma única função objetivo. Trata-se da forma mais clássica de otimização, amplamente utilizada em problemas em que o critério de desempenho é bem definido, como a minimização de custos, maximização de eficiência ou a redução de peso em projetos estruturais (Cabral, 2016).

Esse tipo de problema pode ser resolvido por técnicas analíticas, métodos numéricos baseados em gradientes ou por algoritmos heurísticos, dependendo da complexidade e da natureza do modelo (Arora, 2011).

### *B. Otimização multiobjetivo*

Em muitos sistemas reais, especialmente na engenharia, é comum que mais de um critério precise ser considerado simultaneamente. Nestes casos, utiliza-se a otimização multiobjetivo, em que duas ou mais funções objetivo são otimizadas de forma concorrente (Marler; Arora, 2004).

Essas funções podem ser conflitantes entre si, exigindo a geração de um conjunto de soluções de compromisso conhecido como fronteira de Pareto.

### *C. Problemas com restrições*

A grande maioria dos problemas práticos apresenta restrições que limitam o espaço de busca viável. Essas restrições podem ser de igualdade (por exemplo, balanço de forças) ou desigualdade (como limites operacionais de equipamentos) (Martins, 2011).

A inclusão de restrições torna o problema mais realista e desafiador, exigindo técnicas específicas para garantir que as soluções geradas permaneçam viáveis (Tancredi, 2008).

### *D. Otimização contínua e discreta*

Outra distinção importante está relacionada à natureza das variáveis de decisão. Na otimização contínua, as variáveis assumem valores dentro de intervalos

reais, como dimensões de um componente estrutural (Cabral, 2016). Já na otimização discreta, as variáveis assumem apenas valores inteiros ou pertencem a conjuntos finitos, tais como o número de equipamentos, posições ou estados (Cabral, 2016). Problemas com variáveis mistas (contínuas e discretas) também são comuns e requerem técnicas híbridas para sua resolução (Aussourd, 2015).

### *E. Otimização estática e dinâmica*

Por fim, distingue-se a otimização estática da dinâmica. Na otimização estática, o sistema é analisado em um estado estacionário, enquanto na otimização dinâmica, o processo considera a evolução temporal das variáveis, exigindo modelagem baseada em equações diferenciais e controle ótimo (Arora, 2011).

### **2.7.3 Algoritmos de otimização tradicionais**

A resolução de problemas de otimização pode ser realizada por diferentes algoritmos, cuja escolha depende da natureza do problema, da função objetivo, das variáveis de decisão e das restrições envolvidas. Os algoritmos tradicionais de otimização são frequentemente classificados como métodos determinísticos e têm sua origem na matemática aplicada e na análise numérica (Bazaraa, Sherali & Shetty, 2006).

Esses métodos se destacam por oferecerem rigor teórico, boas taxas de convergência e, em muitos casos, garantias de encontrar soluções ótimas locais ou globais, desde que o problema seja bem-comportado. Embora não sejam o foco principal deste trabalho, é importante reconhecê-los em termos gerais.

O método do gradiente utiliza derivadas de primeira ordem para determinar a direção de descida mais rápida da função objetivo, enquanto o método de Newton incorpora informações de segunda ordem (matriz Hessiana) para acelerar a convergência (Nocedal; Wright, 2006). Para problemas com restrições de igualdade, a técnica dos multiplicadores de Lagrange transforma o problema original em uma função Lagrangiana, permitindo encontrar pontos de sela que satisfazem as condições ótimas (Arora, 2011).

Na programação linear, quando a função e as restrições são lineares, o algoritmo Simplex resolve de modo eficiente problemas de grandes dimensões

(Winston, 2009), enquanto a programação não linear emprega métodos de penalidade, barreira e busca sequencial para lidar com não linearidades em funções e restrições (Cabral, 2016).

Embora rigorosos e teoricamente robustos, esses métodos podem ficar restritos a mínimos locais e ter desempenho limitado em problemas multimodais ou com múltiplos objetivos conflitantes. Por esse motivo, este trabalho utiliza algoritmos evolutivos, notadamente o NSGA-II, que exploram amplamente o espaço de soluções e geram fronteiras de Pareto em presença de restrições complexas e objetivos simultâneos.

#### **2.7.4 Algoritmos de otimização heurística e metaheurísticas**

Algoritmos heurísticos e metaheurísticos surgiram como alternativas aos métodos tradicionais de otimização, especialmente em contextos nos quais o espaço de busca é altamente não linear, multidimensional, descontínuo ou de difícil modelagem matemática (Blum; Rolí, 2003).

Diferentemente dos métodos determinísticos, essas abordagens não garantem a obtenção da solução ótima global, mas são capazes de encontrar soluções satisfatórias em tempo computacional razoável, mesmo diante de problemas complexos e com múltiplas restrições (Goldberg, 1989).

As heurísticas são estratégias empíricas, muitas vezes inspiradas em soluções práticas, que conduzem a busca com base em regras específicas, conhecimento prévio ou experiência do domínio (Rolí et al., 2003). Já as metaheurísticas são estruturas de alto nível que orientam a aplicação de heurísticas locais, incorporando mecanismos de intensificação (exploração detalhada de regiões promissoras) e diversificação (exploração global) para evitar mínimos locais e promover uma cobertura mais eficaz do espaço de busca (Rao et al., 2007).

Essas técnicas mostram-se especialmente úteis quando o modelo matemático é desconhecido ou intratável, a função objetivo é não diferenciável, ruidosa ou descontínua, há elevado número de variáveis e restrições, ou quando se precisa explorar rapidamente um amplo espaço de soluções sob restrições de tempo (Khan, 2020).

Entre as principais metaheurísticas aplicadas na engenharia, destacam-se:

### *A. Algoritmos genéticos (AG)*

Inspirados nos princípios da evolução biológica e seleção natural, os algoritmos genéticos trabalham com uma população de soluções representadas como cromossomos (Goldberg, 1989).

Por meio dos operadores de seleção, cruzamento e mutação, os indivíduos evoluem geração após geração, promovendo uma busca global eficaz em espaços complexos (Holland, 1975). Essa abordagem é amplamente utilizada em otimização de projetos, ajuste de parâmetros e problemas com variáveis mistas.

### *B. Outras heurísticas e metaheurísticas clássicas*

A otimização por enxame de partículas (PSO) representa soluções como partículas que se deslocam influenciadas por suas melhores posições individuais e coletivas, proporcionando simplicidade de implementação e boa convergência em problemas contínuos (Kennedy; Eberhart, 1995).

O algoritmo de colônia de formigas (ACO) baseia-se no depósito de feromônio por agentes que constroem soluções de forma probabilística, sendo eficaz em roteamento e planejamento de trajetórias (Dorigo; Stützle, 2004). Já os algoritmos híbridos combinam paradigmas determinísticos, heurísticos e metaheurísticos, por exemplo, mesclando algoritmos genéticos para exploração global com métodos de gradiente para refinamento local, o que pode melhorar eficiência e qualidade das soluções em otimização complexa (Rao et al., 2007; Khan, 2020).

Embora este trabalho utilize algoritmos genéticos, como o NSGA-II, entende-se que heurísticas e metaheurísticas oferecem um conjunto rico de ferramentas que podem ser integradas ou adaptadas quando necessário para lidar com as particularidades de projetos offshore envolvendo sistemas de ancoragem.

#### **2.7.5 Processo de otimização**

O processo de otimização visa identificar a melhor configuração possível de um sistema, a partir de um conjunto de critérios e restrições previamente definidos. Em engenharia, essa abordagem é essencial para lidar com problemas complexos e

multidimensionais, nos quais o objetivo é alcançar soluções eficientes, viáveis e tecnicamente equilibradas.

A formulação adequada do problema de otimização requer a definição clara de variáveis de projeto, funções objetivo, restrições e, por fim, a representação do modelo matemático que interliga esses elementos (Rao, 2009).

#### 2.7.5.1 *Variáveis*

As variáveis de projeto representam os parâmetros ajustáveis do sistema que influenciam diretamente seu comportamento e desempenho. Elas podem ser classificadas como contínuas ou discretas, a depender da natureza dos valores que podem assumir.

A escolha das variáveis relevantes está diretamente associada à compreensão do sistema e ao conhecimento técnico sobre o problema. Uma seleção inadequada pode resultar em baixa eficiência do processo ou inviabilidade das soluções geradas (Tancredi, 2008).

#### 2.7.5.2 *Função objetivo*

A função objetivo é uma expressão matemática que quantifica o desempenho do sistema em relação aos critérios a serem otimizados, podendo envolver aspectos como custo, segurança, eficiência estrutural ou estabilidade (Deb, 2001).

Em muitos problemas de engenharia, há múltiplos objetivos conflitantes, o que leva à adoção de técnicas de otimização multiobjetivo. A formulação adequada da função objetivo é fundamental para garantir que o processo de busca conduza a soluções alinhadas com os requisitos do projeto.

#### 2.7.5.3 *Restrições*

As restrições impõem limites ao espaço de busca, refletindo aspectos físicos, operacionais, econômicos ou normativos que o sistema deve obedecer. Elas podem ser do tipo igualdade ou desigualdade, e têm como papel principal garantir

que as soluções propostas sejam factíveis e tecnicamente aceitáveis (NOCEDAL; WRIGHT, 2006).

#### 2.7.5.4 *Modelo matemático*

O modelo matemático integra todas as informações do problema de otimização, interligando variáveis, objetivos e restrições em uma estrutura lógica. A modelagem pode assumir formas analíticas, empíricas ou numéricas, dependendo da complexidade do sistema e da disponibilidade de dados.

Segundo Rao (2009), a precisão e representatividade do modelo são determinantes para o sucesso do processo de otimização, sendo necessário garantir que ele reflita fielmente o comportamento do sistema real.

#### **2.7.6 Algoritmos genéticos**

Os Algoritmos Genéticos (AG) são métodos de otimização baseados em mecanismos inspirados na evolução biológica, concebidos por John Holland na década de 1970 (Silva, 2012). Fundamentados na teoria da seleção natural proposta por Darwin, os AGs simulam, em ambiente computacional, o processo evolutivo das espécies para resolver problemas complexos de busca e otimização.

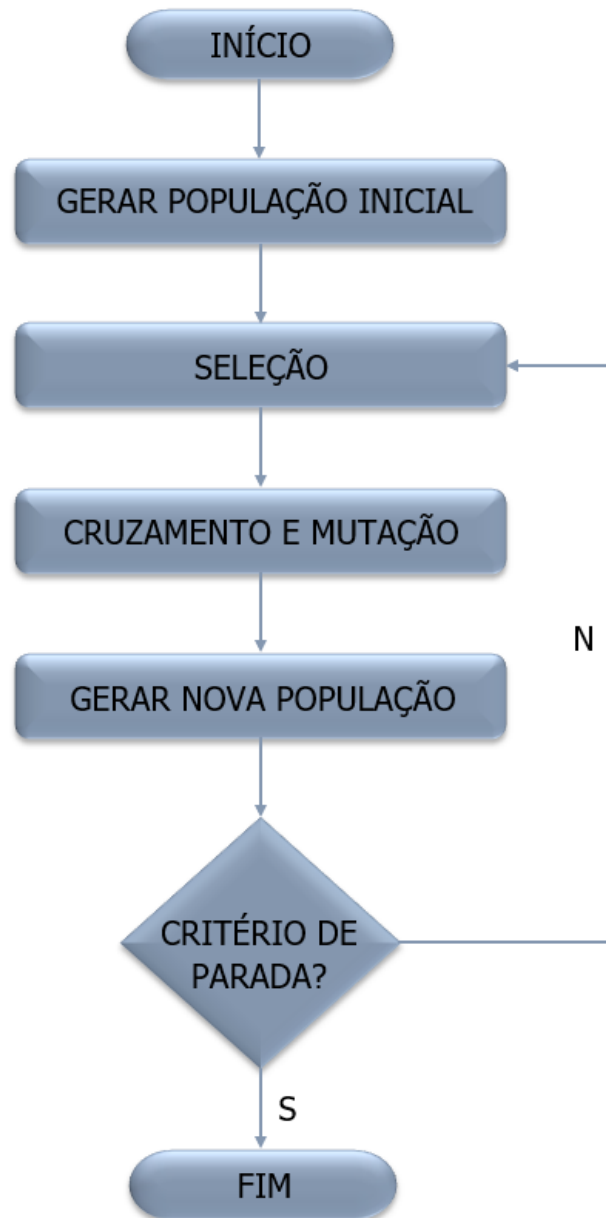
Ao operar sobre populações de soluções candidatas, os AGs aplicam operadores genéticos, que atuam iterativamente na geração de novas soluções, promovendo a exploração eficiente de grandes e complexos espaços de busca (Marson, 2017). Essa abordagem se destaca por sua robustez frente a funções objetivo não lineares, não diferenciáveis ou com múltiplos ótimos locais.

Em aplicações de engenharia, como no projeto de sistemas de ancoragem offshore, os AGs são amplamente utilizados devido à sua capacidade de lidar com múltiplas variáveis, restrições complexas e objetivos conflitantes. Eles também se integram facilmente a plataformas computacionais, permitindo simulações em larga escala e análise de soluções em cenários realistas e exigentes.

Embora existam diversas variantes, a estrutura geral de um algoritmo genético segue um fluxo básico, representado na Figura 16. Esse fluxograma

sintetiza as etapas essenciais que compõem a dinâmica evolutiva dos algoritmos genéticos.

Figura 16 – Fluxograma geral de um algoritmo genético.



Fonte: Adaptado de Tancredi (2008).

Inicialmente, o processo se inicia com uma população inicial, e, por meio de iterações sucessivas de evolução, uma nova população emerge, apresentando aprimoramentos graduais nas soluções para o problema em consideração (Silva, 2012). A seleção dos indivíduos mais aptos ocorre em cada etapa do processo,

seguida pela aplicação de cruzamento e mutação, garantindo a geração de uma descendência distinta (Marson, 2017).

Em cada ciclo desse processo evolutivo, a seleção dos indivíduos com melhor desempenho é crucial, sendo seguida pelo cruzamento, que combina os cromossomos parentais para gerar cromossomos filhos (Filitto, 2008). O papel essencial do operador de mutação entra em cena, introduzindo mudanças aleatórias nos cromossomos gerados, nesse sentido, esse ciclo iterativo continua até que a solução desejada seja alcançada, destacando a abordagem dinâmica e adaptativa dos algoritmos genéticos na exploração eficaz do espaço de soluções (Catarina, 2005).

O objetivo subjacente do cruzamento e da mutação é promover a diversidade genética, garantindo que os cromossomos resultantes se diferenciem dos cromossomos parentais, enriquecendo a busca pela solução ótima (Filitto, 2008).

Além disso, a eficácia dos algoritmos genéticos está intrinsecamente ligada ao controle de parâmetros essenciais, tais como as taxas de cruzamento e mutação. A determinação precisa desses parâmetros desempenha um papel crítico na dinâmica do algoritmo, influenciando a exploração do espaço de busca e a convergência para soluções ótimas (Bastos, 2017). Assim, a definição cuidadosa desses valores se torna uma parte integral da implementação bem-sucedida dessa abordagem de otimização.

Os algoritmos genéticos também demonstram uma notável flexibilidade ao lidar tanto com problemas mono quanto multiobjetivos. Em problemas mono-objetivos, o foco está na otimização de um único objetivo, buscando encontrar a solução mais eficiente em um único critério (Cruz, 2022). Por outro lado, em contextos multiobjetivos, a versatilidade dos algoritmos genéticos se revela na habilidade de encontrar soluções de pareto, equilibrando os objetivos conflitantes (Bastos, 2017).

Essa característica torna os algoritmos genéticos ideais para cenários complexos nos quais a busca por soluções ótimas exige a consideração de múltiplos critérios, como custo, desempenho e sustentabilidade (Linczuk; Bastos, 2020). Essa capacidade de equilibrar compromissos entre diferentes objetivos faz dos algoritmos genéticos uma ferramenta versátil para a resolução de problemas complexos em ambientes diversos, desde a engenharia até a tomada de decisões estratégicas.

Diversos algoritmos de otimização desempenham um papel crucial na busca pela solução ótima em projetos de ancoragem de plataformas oceânicas. Entre essas abordagens, destaca-se o uso de algoritmos genéticos, com ênfase especial no algoritmo NSGA-II, que será empregado nas análises abordadas neste trabalho.

#### 2.7.6.1 *Algoritmo NSGA-II*

A otimização de problemas complexos com múltiplos objetivos é uma tarefa desafiadora, e o algoritmo de Classificação por Não Dominância II (NSGA-II) surge como uma ferramenta eficaz para enfrentar esse desafio. Proposto por K. Deb, S. Agrawal, A. Pratap e T. Meyarivan em 2002, o NSGA-II é uma extensão do NSGA original, projetado para lidar com problemas multiobjetivo (Bastos, 2017). Seu diferencial reside na abordagem de não dominância, que classifica soluções com base em sua superioridade em relação às demais, sem depender de uma única função objetivo (Gimenes, 2020).

O NSGA-II opera seguindo um ciclo evolutivo, iniciando com a geração de uma população inicial de soluções candidatas (Herrera; Attux; Coelho, 2021). Cada solução é então avaliada quanto aos objetivos do problema, resultando na atribuição de um valor de fitness (Ayres et al., 2007). Também segundo os autores, esta avaliação não apenas quantifica a qualidade de cada solução, mas também estabelece uma classificação baseada no conceito de não dominância.

A classificação por não dominância leva à formação de fronteiras de pareto, onde cada fronteira representa soluções que não são superadas por nenhuma outra em todos os objetivos (Bastos, 2017). Soluções dessas fronteiras são consideradas promissoras e selecionadas como pais para a próxima geração. Aqui, operadores genéticos, como crossover e mutação, são aplicados, gerando uma nova geração de soluções, conhecida como descendentes (Herrera; Attux; Coelho, 2021).

Esses descendentes, juntamente com os pais, formam uma nova população que é novamente submetida à avaliação de fitness e ao processo de classificação por não dominância (Linczuk; Bastos, 2020). O ciclo iterativo continua por várias gerações, permitindo que o algoritmo explore o espaço de busca de maneira eficiente.

O processo de seleção, reprodução e avaliação busca encontrar um equilíbrio entre explorar novas regiões do espaço de busca e aprimorar soluções

conhecidas (Silva, 2012). A reclassificação das soluções a cada iteração assegura diversidade nas soluções mantidas.

O algoritmo persiste até que critérios de convergência sejam atendidos, tais como um número máximo de gerações ou a convergência das soluções (Linczuk; Bastos, 2020). O resultado é um conjunto de soluções ótimas e bem distribuídas, representando um compromisso eficiente entre objetivos conflitantes. O fluxograma apresentado na Figura 17 representa o ciclo típico de uma iteração do NSGA-II.

Figura 17 – Fluxograma do ciclo típico de uma iteração do NSGA-II.



Fonte: Adaptado de Camara (2021).

O NSGA-II, ao adotar uma abordagem iterativa baseada na não dominância, destaca-se como uma ferramenta robusta para resolver desafios de otimização multiobjetivo.

Sua capacidade de equilibrar eficiência computacional e diversidade nas soluções produzidas o torna aplicável em uma variedade de contextos práticos. Compreender o funcionamento detalhado do NSGA-II auxilia na abordagem de problemas complexos, buscando soluções ótimas em ambientes desafiadores.

## 2.8 FUNDAMENTOS DA INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é um campo multidisciplinar da ciência da computação que se dedica ao desenvolvimento de sistemas capazes de realizar

tarefas que, tradicionalmente, requerem inteligência humana (Poole; Mackworth; Goebel, 2017). Essas tarefas incluem a capacidade de aprender a partir de dados, identificar padrões, tomar decisões e adaptar-se a ambientes variáveis (Russell; Norvig, 2021). A IA busca não apenas automatizar processos, mas também criar mecanismos computacionais capazes de simular habilidades cognitivas complexas, como raciocínio, previsão e reconhecimento de padrões (Ghallab; Nau; Traverso, 2016).

Desde seu surgimento nas décadas de 1950 e 1960, a IA tem evoluído significativamente, incorporando avanços nas áreas de estatística, matemática, lógica, processamento de linguagem natural e aprendizado de máquina (Poole; Mackworth, 2017). Seu escopo de aplicação expandiu-se para setores como saúde, finanças, transporte, manufatura e, mais recentemente, engenharia naval e offshore. Nestes setores, a IA é empregada para resolver problemas caracterizados por elevada complexidade, alto volume de dados e variabilidade operacional.

A aplicação da IA em problemas de engenharia, especialmente no ambiente offshore, tem se mostrado promissora devido à sua capacidade de reduzir custos computacionais associados a simulações tradicionais e de gerar soluções consistentes em cenários complexos (Yee; Mohamed; Montasir, 2021). Técnicas de IA permitem não apenas a análise de dados históricos e operacionais, mas também a construção de modelos preditivos que substituem ou complementam métodos de análise convencionais.

De maneira geral, a IA abrange diferentes paradigmas e técnicas. Segundo Gupta et al. (2021), a IA engloba métodos como aprendizado de máquina (Machine Learning), aprendizado profundo (Deep Learning), redes neurais artificiais (RNAs), máquinas de vetores de suporte, classificação e regressão, redes adversariais generativas (GANs), aprendizado simbólico e meta-aprendizagem.

No âmbito do Machine Learning, é possível identificar cinco correntes principais, classificadas com base em suas inspirações ou abordagens (Russell; Norvig, 2021). Os simbolistas baseiam-se em lógica e filosofia, empregando métodos dedutivos para modelar conhecimento e tomar decisões (Ghallab et al., 2016). Os conexionistas, por sua vez, inspiram-se na neurociência e buscam imitar a estrutura de redes neurais biológicas para interpretar padrões e dados interconectados (Goodfellow; Bengio; Courville, 2016). Já os evolucionários utilizam princípios da teoria da evolução biológica, como seleção natural e adaptação, para

orientar a evolução de algoritmos (Mitchell, 2019). Os analogizadores fundamentam-se na psicologia, aplicando analogias para resolver novos problemas a partir de experiências anteriores (Russell; Norvig, 2021). Por fim, os bayesianos são baseados em estatística e probabilidade, utilizando inferência probabilística para atualizar estimativas conforme novas informações se tornam disponíveis (Barber, 2017).

Além disso, de acordo com a necessidade de supervisão humana durante o treinamento, os algoritmos de Machine Learning podem ser classificados em diferentes categorias. No aprendizado supervisionado, o modelo aprende a partir de dados rotulados, generalizando padrões que permitem prever novos casos (Mohri; Rostamizadeh; Talwalkar, 2018). Já no aprendizado não supervisionado, o modelo identifica padrões ocultos em dados não rotulados, sem a necessidade de orientação explícita (Aggarwal; Reddy, 2014).

Há ainda o aprendizado semi-supervisionado, que combina dados rotulados e não rotulados no processo de treinamento, buscando maior eficiência mesmo com menor quantidade de dados anotados (Chapelle; Scholkopf; Zien, 2010). Por fim, o aprendizado por reforço baseia-se em um mecanismo de tentativa e erro, em que o agente aprende a maximizar recompensas ao interagir com o ambiente, mesmo na ausência de supervisão constante (Sutton; Barto, 2018).

As redes neurais artificiais (RNAs) são uma técnica central no aprendizado de máquina, integrando-se à corrente conexionista da IA. Inspiradas na estrutura e funcionamento dos neurônios biológicos, as RNAs têm como principal objetivo construir modelos capazes de extrair características relevantes dos dados e realizar previsões complexas, mesmo em contextos altamente variáveis (Goodfellow; Bengio; Courville, 2016).

Sua capacidade de identificar padrões e generalizar o comportamento dos sistemas as torna especialmente adequadas para aplicações que demandam elevado grau de adaptabilidade e precisão (LeCun; Bengio; Hinton, 2015).

Assim, no contexto desta dissertação, o foco será direcionado para o uso de redes neurais artificiais. Estas técnicas demonstram elevado potencial para a modelagem de fenômenos complexos em sistemas offshore, permitindo a substituição parcial de simulações dinâmicas tradicionais por modelos preditivos mais rápidos e eficientes.

Nos próximos tópicos, serão detalhados o funcionamento, as arquiteturas e a aplicação das RNAs no desenvolvimento do modelo de previsão das variáveis críticas do sistema de ancoragem.

### **2.8.1 Redes neurais artificiais**

As redes neurais artificiais (RNAs) representam um avanço notável no campo da inteligência artificial, tendo como objetivo replicar, de forma computacional, aspectos da complexidade e adaptabilidade do sistema nervoso biológico (Ferreira, 2020).

Inspiradas pelo funcionamento dos neurônios humanos, as RNAs consistem em arranjos de unidades de processamento conhecidas como neurônios artificiais, conectadas entre si por pesos sinápticos ajustáveis (Santos, 2018). Essas redes são capazes de modelar relações não lineares complexas entre variáveis de entrada e saída, mesmo em situações em que a formulação explícita do problema seria inviável ou de alta complexidade.

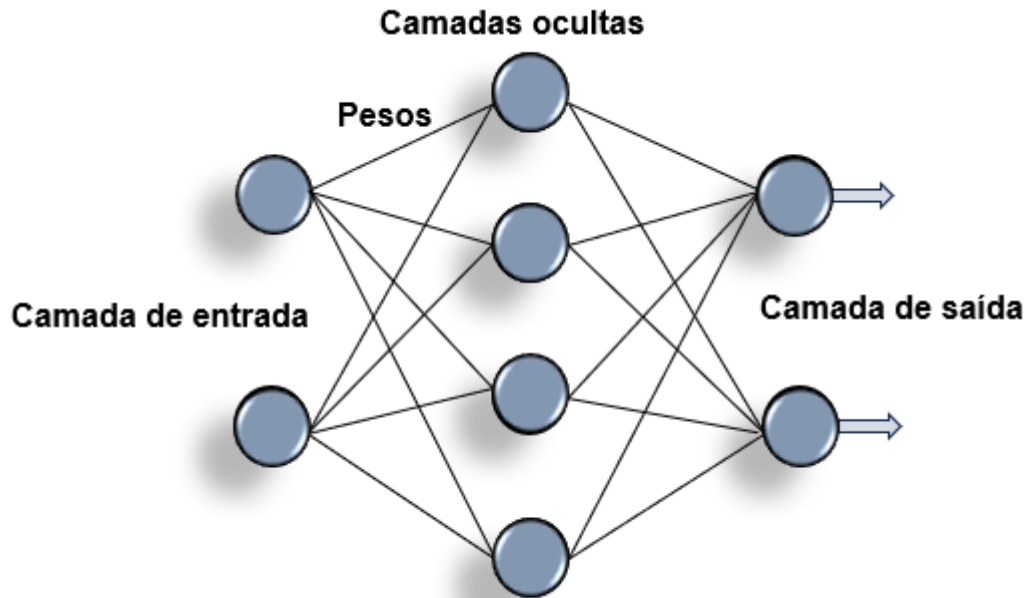
O poder das RNAs reside em sua capacidade de aprendizado e generalização, possibilitando a modelagem de relações complexas entre variáveis e a tomada de decisões com base em padrões extraídos de dados (Felisbino, 2012). Por incorporarem princípios biológicos, as RNAs são capazes de realizar tarefas de associação, generalização, reconhecimento de padrões e inferência em cenários ruidosos ou incompletos (Silva; Spatti; Flauzino, 2010). Sua aplicabilidade se estende a uma ampla gama de problemas, como previsão de séries temporais, classificação de imagens, reconhecimento de voz, modelagem de sistemas físicos e análise de dados industriais.

A arquitetura típica de uma RNA é composta por três tipos de camadas: a camada de entrada, que recebe os dados; uma ou mais camadas ocultas, responsáveis pela extração de características e processamento interno; e a camada de saída, que entrega o resultado (Ferreira, 2020).

Essa estrutura, representada na Figura 18, confere às redes neurais grande flexibilidade para lidar com diferentes tipos de problemas de classificação, regressão e previsão. A profundidade da rede, isto é, o número de camadas ocultas, e o número de neurônios por camada influenciam diretamente a capacidade do modelo

de capturar padrões complexos e realizar aproximações mais precisas (Goodfellow; Bengio; Courville, 2016).

Figura 18 – Exemplo de uma rede neural artificial.



Fonte: Adaptado de Neigrado (2022).

O processo de aprendizado das RNAs baseia-se na exposição da rede a dados de treinamento rotulados, ajustando os pesos das conexões entre os neurônios para minimizar uma função de custo que mede o erro entre as previsões da rede e os valores reais (Minussi; Lotufo, 2008). A técnica mais comum para este ajuste é a retropropagação do erro (backpropagation), associada a métodos de otimização como o gradiente descendente (Medeiros, 2019).

Os neurônios aplicam funções de ativação às entradas ponderadas, determinando se a informação será propagada para as camadas seguintes. Funções como a sigmoide, a tangente hiperbólica e a ReLU (Rectified Linear Unit) introduzem não linearidades essenciais ao modelo, permitindo que a RNA capture relações complexas entre as variáveis de entrada e de saída (Haykin, 2001).

A capacidade de generalização das RNAs depende de fatores como a quantidade e a qualidade dos dados de treinamento, a complexidade da rede (número de camadas e neurônios), a escolha das funções de ativação, o método de otimização e a estratégia de regularização empregada (Silva; Spatti; Flauzino, 2016). Problemas como o overfitting, caracterizado pela memorização excessiva dos dados

de treinamento e perda de capacidade de generalizar para novos dados, devem ser cuidadosamente controlados por meio de técnicas como validação cruzada, dropout e EarlyStopping (Goodfellow; Bengio; Courville, 2016).

Além disso, em aplicações práticas, a escolha da função de perda (por exemplo, erro quadrático médio para regressão ou entropia cruzada para classificação) e do otimizador (como Adam, RMSprop ou SGD) são fatores críticos para o sucesso do treinamento da RNA.

Uma aplicação relevante dessa abordagem é apresentada no estudo de Daer (2017), relacionado a plataformas flutuantes de produção de petróleo offshore. Neste trabalho, RNAs foram empregadas para estimar deslocamentos (offsets) e tensões máximas em linhas de ancoragem, substituindo simulações dinâmicas tradicionais, que apresentam elevado custo computacional. Posteriormente, um processo de otimização adicional, utilizando algoritmos evolucionários, foi integrado para refinar ainda mais os resultados. Essa metodologia demonstrou ser eficiente tanto na redução do tempo de processamento quanto na manutenção da precisão dos resultados, evidenciando o potencial das RNAs em projetos offshore de alta complexidade.

Assim, as redes neurais artificiais configuram-se como uma poderosa ferramenta para a modelagem e previsão de sistemas offshore complexos, possibilitando análises mais rápidas, precisas e eficientes em comparação com métodos tradicionais de simulação.

## 2.9 TRABALHOS RELACIONADOS

Na literatura sobre sistemas offshore e ancoragem de plataformas, diversos estudos abordam questões relevantes para o projeto eficiente dessas estruturas. Carbono (2005) oferece uma perspectiva sobre a disposição das linhas de ancoragem, utilizando algoritmos genéticos para otimizar a distribuição dessas estruturas em unidades flutuantes, o que também de forma similar é empregado inicialmente no estudo. Ao concentrar-se na minimização dos deslocamentos das unidades flutuantes em resposta a fatores ambientais, como ventos, ondas e correntes, o trabalho destaca a relevância de estratégias eficientes na disposição das linhas de ancoragem para garantir a não movimentação da unidade durante as operações de exploração de petróleo em águas profundas.

Albrecht (2005) desenvolveu uma ferramenta computacional dedicada à otimização de sistemas de ancoragem, cruciais nas operações de exploração de petróleo, com foco nos deslocamentos experimentados por unidades flutuantes e nas tensões nas linhas de ancoragem. Nesse estudo, o pesquisador emprega um algoritmo fundamentado nos princípios da computação evolucionária para abordar eficazmente os desafios associados à disposição estratégica dessas linhas essenciais.

Expandindo o foco para aprendizado de máquina, tem-se o trabalho de Andrade, Martins e Lages (2015), o qual explorou as análises de linhas de ancoragem em configuração de catenária simples, destacando a importância desses elementos na minimização dos deslocamentos das plataformas flutuantes em ambientes marítimos. Os autores apresentaram uma abordagem inovadora ao integrar redes neurais artificiais na análise e previsão da resposta das linhas de ancoragem, demonstrando a capacidade dessas redes em fornecer resultados precisos e eficientes em comparação com métodos tradicionais, como o método dos elementos finitos. Essa integração de tecnologias emergentes, como as RNA, evidencia a constante busca por métodos mais avançados e eficazes no projeto de sistemas de ancoragem para plataformas offshore, contribuindo para a evolução contínua da engenharia nesse campo específico.

Já o trabalho de Garcia (2023) complementa essa perspectiva ao investigar o potencial do uso de redes neurais artificiais na análise de dados experimentais. O foco central do estudo de Garcia é a previsão de tensões em linhas de ancoragem a partir de dados de posição. A comparação entre os resultados fornecidos pela inteligência artificial e os procedimentos tradicionais realizados em software específico fornece insights valiosos sobre o desempenho das RNA nesse contexto específico.

Além dos estudos previamente mencionados, é relevante destacar a contribuição significativa do trabalho de Pina (2010) para o campo do design de estruturas offshore. Este trabalho aborda metodologias de otimização, utilizando o método de enxame de partículas (PSO) e redes neurais artificiais (RNA). A pesquisa propõe abordagens inovadoras para otimizar o design de estruturas offshore, utilizando PSO para buscar soluções eficientes. Além disso, a aplicação de metamodelos, incluindo o uso de RNA, busca reduzir consideravelmente o tempo computacional necessário para análises cruciais, como a série temporal de tração no

topo de risers e linhas de ancoragem. Ao incorporar essas metodologias, o estudo de Pina (2010) almeja resultados robustos para configurações de linhas de ancoragem e risers, disputando com análises tradicionais de elementos finitos, mas com uma notável redução no tempo de processamento.

Mais recentemente, outras abordagens vêm ampliando o uso de redes neurais no contexto offshore. Nikkhah (2021) aplicou redes neurais artificiais combinadas com métodos preditivos para avaliar a integridade estrutural de sistemas de ancoragem em unidades FPSO, permitindo a identificação antecipada de falhas sob diferentes cenários operacionais.

No mesmo sentido, Martzikos et al. (2024) desenvolveram um modelo baseado em redes neurais para prever as respostas dinâmicas de plataformas offshore, integrando dados hidrodinâmicos e ambientais com o objetivo de aprimorar a precisão das previsões. Payenda et al. (2024), por sua vez, propuseram o uso de uma arquitetura baseada em redes neurais recorrentes (RNN) para estimar tensões em linhas de ancoragem de unidades flutuantes, demonstrando a capacidade desses modelos em capturar comportamentos dependentes do tempo com menor custo computacional em comparação com simulações numéricas tradicionais.

Esses trabalhos convergentes contribuem para o avanço contínuo no entendimento e na aplicação da otimização e do uso de redes neurais artificiais em problemas relacionados à ancoragem de plataformas offshore, destacando a diversidade de abordagens e aplicações dessas ferramentas na engenharia naval. Essa base sólida estabelecida pelos estudos anteriores reforça a importância de pesquisas que integrem técnicas computacionais avançadas no projeto, análise e monitoramento de sistemas offshore.

### **3 METODOLOGIA**

Neste capítulo é descrita a metodologia empregada para o desenvolvimento do projeto, com foco na integração das técnicas de otimização e da modelagem preditiva baseadas em inteligência artificial. A abordagem foi estruturada de forma a assegurar a eficiência do processo, a confiabilidade dos resultados e a aderência às práticas recomendadas para sistemas offshore, permitindo uma análise aprofundada de todas as etapas envolvidas no desenvolvimento do projeto.

Inicialmente, são apresentadas as ferramentas computacionais utilizadas; na sequência, descreve-se a estruturação do modelo de otimização, com a definição das variáveis, função objetivo, restrições, DOEs e construção do modelo; por fim, aplica-se a metodologia proposta em um estudo de caso.

#### **3.1 FERRAMENTAS DE OTIMIZAÇÃO**

Ferramentas computacionais têm sido desenvolvidas para apoiar a formulação, modelagem e resolução de problemas complexos de otimização em engenharia. Entre elas, destacam-se o Synapse, uma plataforma genérica e extensível voltada à construção de modelos de otimização em diferentes domínios, e o Synapse Offshore, uma aplicação especializada no setor naval e offshore. A seguir, apresentam-se as principais características de cada ferramenta.

##### **3.1.1 Synapse**

O Synapse é um ambiente computacional voltado ao desenvolvimento de modelos de otimização mono e multiobjetivo, além de análise de sensibilidade e interpolação de dados. Desenvolvido originalmente em Delphi e C++, o programa oferece uma plataforma visual onde os elementos do problema (variáveis, parâmetros, funções objetivo, restrições e resultados) são estruturados em blocos interconectáveis, proporcionando flexibilidade, modularidade e rastreabilidade no desenvolvimento de soluções.

Entre seus principais diferenciais, destaca-se a integração com ferramentas como Excel, Ansys, MatLab, Python, Octave e Scilab, além da possibilidade de incorporar rotinas analíticas, modelos estruturais, solvers externos e redes neurais

artificiais (MLP). A interface também suporta experimentos de planejamento (DOE), otimização com diferentes algoritmos (NSGA-II, HDGA, MOGA, Simplex, entre outros), e análise gráfica dos resultados. Seu uso está disseminado em diferentes áreas da engenharia, com foco em projetos que exigem avaliação de variáveis e busca por soluções eficientes com múltiplos critérios.

### **3.1.2 Synapse Offshore**

O Synapse Offshore é uma aplicação especializada do ambiente Synapse, desenvolvida pelo Laboratório de Simulação Naval da Universidade Federal de Santa Catarina, em parceria com empresas como a Petrobras, voltada à otimização de sistemas de ancoragem offshore. Essa ferramenta foi projetada para integrar programas como o Dynasim e o Exmoor, com os algoritmos de otimização disponíveis no Synapse, permitindo a avaliação automática de cenários envolvendo diferentes configurações de linhas, condições ambientais (ondas, vento e corrente) e critérios de projeto (offset, delta yaw, tensões, carga nas âncoras, entre outros).

O Synapse Offshore facilita a modelagem e execução de rotinas complexas de simulação e otimização, reduzindo significativamente o tempo de análise e aumentando a quantidade de alternativas viáveis consideradas no processo de projeto.

## **3.2 ESTRUTURAÇÃO DO PROCESSO DE OTIMIZAÇÃO**

A aplicação das técnicas de otimização no projeto do sistema de ancoragem offshore exige uma etapa prévia de estruturação, na qual são definidos os principais componentes que compõem o modelo computacional. Esse processo inclui a seleção criteriosa das variáveis de projeto, o delineamento da função objetivo, o estabelecimento das restrições, a escolha do método de amostragem (DOE) e a modelagem da lógica de otimização dentro da ferramenta computacional utilizada.

A organização sistemática desses elementos é essencial para garantir coerência ao modelo e permitir sua integração eficiente no ambiente do software Synapse Offshore. O resultado é uma estrutura de otimização adaptada às necessidades específicas do projeto, capaz de explorar o espaço de busca de forma eficaz e gerar soluções alinhadas aos critérios de desempenho definidos.

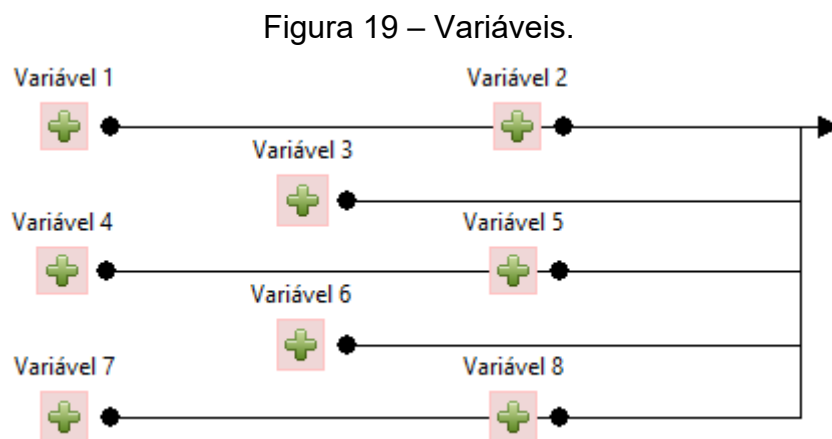
### 3.2.1 Seleção das variáveis

A seleção das variáveis de projeto constitui uma etapa fundamental no processo de modelagem para a otimização. Essas variáveis representam os parâmetros que exercem influência direta no desempenho do sistema, sendo responsáveis por definir os graus de liberdade do modelo. Sua escolha adequada impacta diretamente na eficiência da busca por soluções otimizadas.

Segundo Tancredi (2008), as variáveis podem ser classificadas como contínuas, quando assumem valores dentro de um intervalo real, ou discretas, quando restritas a um conjunto finito de valores, geralmente definidos por critérios técnicos, normativos ou operacionais.

A definição da natureza e dos limites de cada variável deve considerar as características físicas do sistema, os requisitos de projeto e as restrições impostas pelo ambiente de operação.

As variáveis podem ser configuradas no ambiente do programa Synapse, conforme representado na Figura 19. Esse programa permite a parametrização direta dos valores e dos intervalos de variação de cada variável, possibilitando o controle detalhado do espaço de busca a ser explorado.



Fonte: Adaptado do programa Synapse (2024).


A análise crítica e a definição criteriosa dessas variáveis são indispensáveis não apenas para uma modelagem precisa, mas também para garantir que o processo de otimização considere as especificidades do sistema e leve em conta os aspectos técnicos e operacionais relevantes para o projeto offshore.

### 3.2.2 Função objetivo

A função objetivo é um dos elementos centrais em qualquer problema de otimização. Trata-se de uma expressão matemática que visa quantificar o desempenho do sistema a ser otimizado, permitindo a avaliação comparativa entre diferentes configurações de projeto. Sua formulação está diretamente associada aos objetivos do estudo, podendo envolver critérios como eficiência, custo, segurança, estabilidade, entre outros aspectos relevantes ao problema em análise.

De acordo com Tancredi (2008), a função objetivo é composta por grandezas escalares, calculadas a partir dos valores das variáveis de projeto previamente definidas. Essas grandezas são agregadas de forma a representar uma medida de mérito a ser maximizada ou minimizada, conforme os propósitos da análise. A escolha adequada dessa função é essencial para direcionar a busca por soluções viáveis eficazes.

A elaboração cuidadosa e a análise da função objetivo são etapas essenciais, pois ela sintetiza os propósitos do projeto. Ao longo do processo de otimização, a meta é ajustar as variáveis de projeto para otimizar a função objetivo, buscando soluções mais eficientes e alinhadas com os requisitos do projeto (Albrecht, 2005). Na Figura 20, observa-se uma representação da função objetivo modelada no programa Synapse.



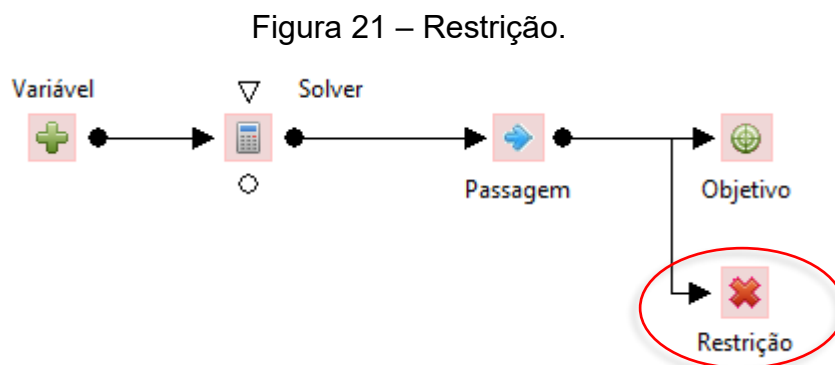
Fonte: Adaptado do programa Synapse (2024).

### 3.2.3 Restrições

A consideração das restrições em problemas de otimização desempenha um papel de extrema importância, influenciando significativamente o curso e os resultados dos projetos. As restrições determinam os limites operacionais dentro dos quais a solução deve ser buscada, refletindo condições técnicas, de segurança, econômicas ou ambientais impostas ao sistema. Sua definição adequada não

apenas assegura a viabilidade prática das soluções, mas também direciona o processo de otimização para regiões viáveis e relevantes do espaço de busca.

A presença ou ausência dessas restrições cria uma dinâmica crucial, pois a definição criteriosa e abrangente desses limites é essencial para estabelecer não apenas as barreiras, mas também as oportunidades dentro do escopo do projeto (Cardoso, 2014). Na Figura 21, observa-se uma representação de uma restrição modelada no programa Synapse.



Fonte: Adaptado do programa Synapse (2024).

Cada restrição adiciona uma camada de complexidade ao problema, desafiando os otimizadores a encontrar soluções viáveis que atendam a todas as condições impostas (Tancredi, 2008). Dessa forma, ao considerar as restrições, é imperativo não apenas reconhecer sua existência, mas também compreender profundamente seu impacto no processo de otimização.

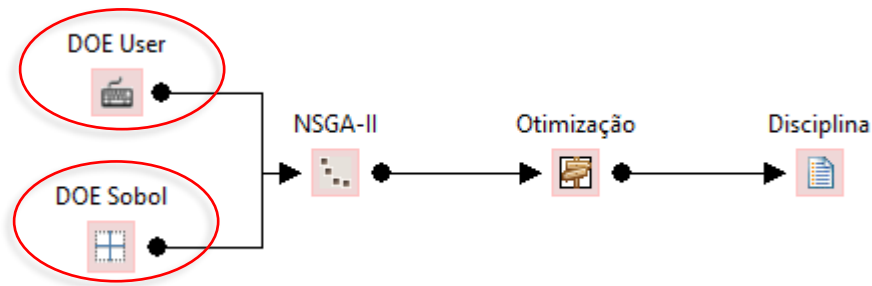
Restrições bem definidas e compreendidas não apenas delineiam as fronteiras do problema, mas também fornecem insights valiosos sobre as possíveis trajetórias de otimização. Por outro lado, segundo Cardoso (2014), a escolha inadequada das restrições pode resultar em soluções sub-ótimas ou inviáveis, comprometendo a eficácia do projeto como um todo.

### 3.2.4 DOEs

As definições de Design of Experiments (DOE) são a primeira etapa no processo de otimização, que consiste na definição das soluções iniciais. Posteriormente, deve-se definir o algoritmo de otimização e o procedimento de otimização. A disciplina, por fim, representa o problema a ser resolvido. Os módulos

DOE User e DOE Sobol, representados no modelo de otimização da Figura 22, correspondem a abordagens distintas utilizadas no planejamento de experimentos voltado à otimização de sistemas ou processos. Ambos os métodos permitem a exploração eficaz do espaço de projeto, mas possuem características distintas.

Figura 22 – DOE User e DOE Sobol.



Fonte: Adaptado do programa Synapse (2024).

A abordagem DOE User permite que o usuário introduza manualmente os valores das variáveis diretamente na interface do sistema (Synapse, 2024), a partir de conhecimento prévio do problema. Nesse caso, o usuário pode especificar os valores das variáveis de projeto para qualquer quantidade desejada de pontos de amostragem. Essa abordagem é flexível e permite ao usuário uma entrada direta, o que pode ser útil quando se deseja testar cenários específicos ou quando se tem um conhecimento detalhado sobre o sistema.

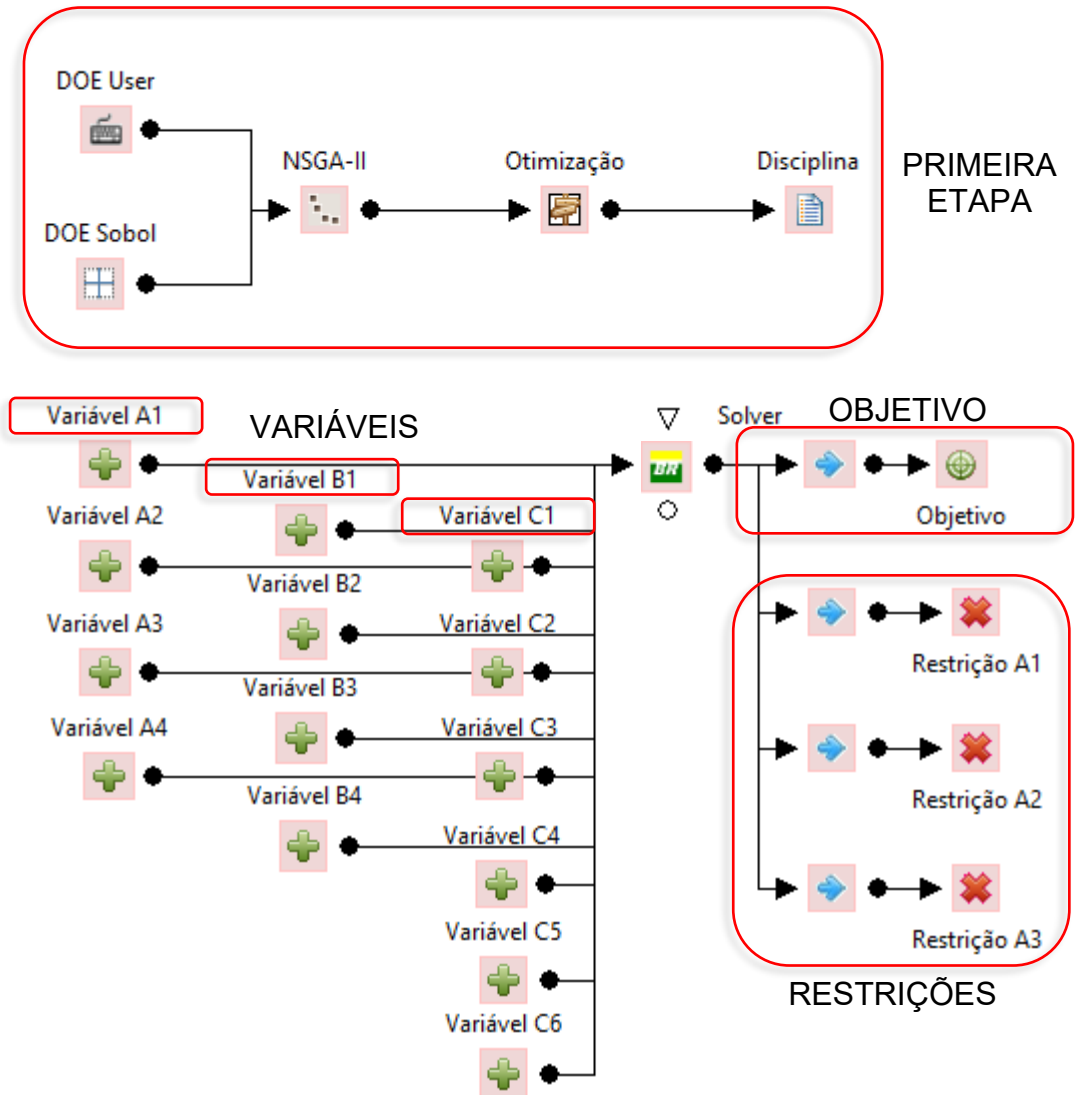
Por outro lado, o DOE Sobol é um algoritmo que automatiza a geração de pontos de amostragem de forma equidistante ao longo de todo o espaço de projeto (Azmin; Stobart, 2015). Esse método é baseado em cálculos estatísticos e matemáticos para determinar pontos que abrangem de maneira uniforme todas as combinações possíveis das variáveis de projeto. Ainda segundo Azmin e Stobart (2015), isso é especialmente útil quando se quer explorar de maneira abrangente o impacto das variáveis em um espectro amplo de cenários.

### 3.2.5 Modelo de otimização

Na Figura 23, apresenta-se parte do modelo de otimização desenvolvido no programa Synapse Offshore. Nesse modelo, destacam-se não apenas o objetivo, mas também as restrições que delineiam as condições e limitações do problema.

Além disso, tornam-se visíveis algumas das variáveis fundamentais associadas a um projeto específico de sistema de ancoragem para uma plataforma offshore.

Figura 23 – Parte do modelo de otimização.



Fonte: Adaptado do programa Synapse (2024).

Essa representação oferece uma compreensão abrangente da estrutura do modelo, proporcionando insights sobre a interconexão entre o objetivo, as restrições e as variáveis essenciais para o sucesso do processo de otimização. A disposição em blocos interconectados facilita a visualização da lógica do modelo, permitindo a verificação de coerência entre os elementos e a rastreabilidade das relações estabelecidas.

A construção gráfica do modelo no ambiente do Synapse Offshore também viabiliza ajustes rápidos e a inserção de novas condições, o que é particularmente

útil em projetos offshore sujeitos a múltiplos cenários e requisitos técnicos. Essa estrutura modelada servirá de base para a aplicação prática descrita na próxima seção, na qual a metodologia será implementada em um estudo de caso representativo.

### 3.3 ESTUDO DE CASO

Para a aplicação da metodologia proposta, elaborou-se um estudo de caso realista, o qual foi dividido em três etapas inter-relacionadas, visando validar a abordagem integrada de otimização e predição de desempenho. Na primeira etapa, realizou-se a otimização inicial do sistema de ancoragem, com a definição da função objetivo, das variáveis de projeto e das restrições técnicas que caracterizam o problema. Para a execução da otimização, empregou-se o algoritmo genético NSGA-II, que foi responsável por explorar o espaço de soluções e identificar a configuração ideal que atendesse aos requisitos estabelecidos.

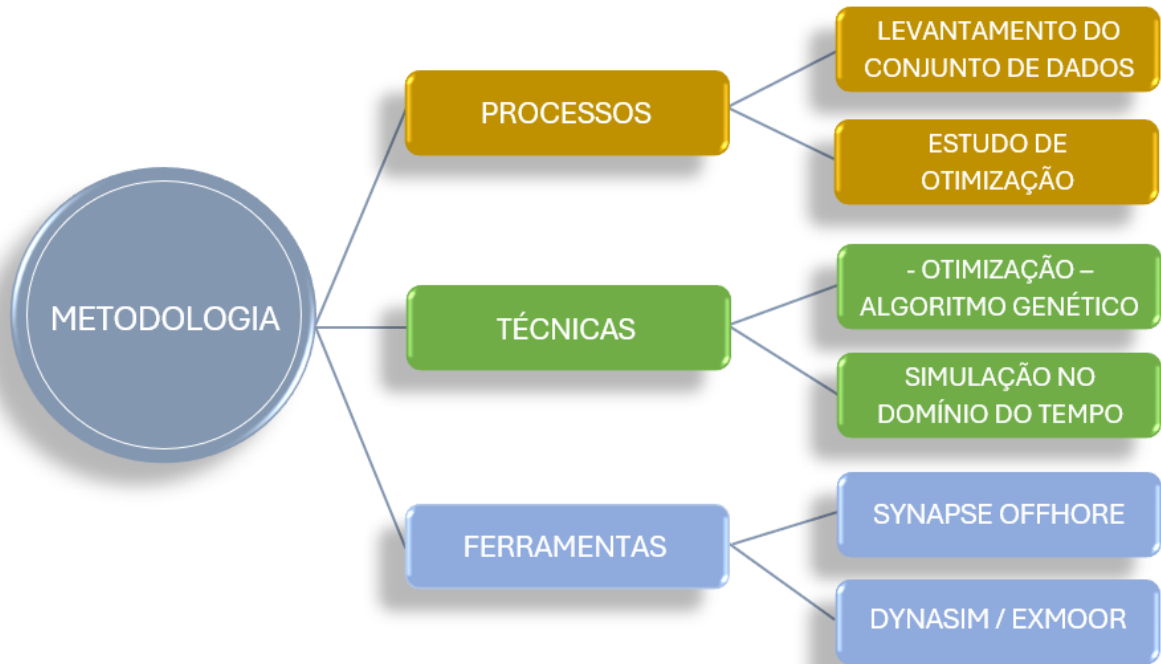
Na segunda etapa, os dados gerados a partir da otimização foram utilizados para o desenvolvimento de um modelo preditivo baseado em redes neurais artificiais (RNAs). O modelo foi treinado utilizando os resultados da primeira fase, visando prever as variáveis de saída essenciais e subsidiar o processo de otimização subsequente. Por fim, na terceira etapa, o modelo preditivo foi empregado para prever novas soluções durante o processo de otimização, e sua verificação foi realizada para confirmar se as previsões estavam em conformidade com os dados reais e os requisitos estabelecidos. A análise possibilitou identificar discrepâncias e realizar os ajustes necessários para aprimorar a acurácia do modelo, garantindo uma base confiável para a melhoria contínua do sistema de ancoragem.

Essa abordagem integrada, que combina otimização, modelagem preditiva e validação, possibilita uma compreensão abrangente do sistema e contribui para a obtenção de uma solução efetiva e alinhada aos objetivos do projeto.

#### 3.3.1 Processo de otimização

O procedimento adotado encontra-se sintetizado na Figura 24, ao passo que os processos, técnicas e ferramentas empregados em cada etapa são detalhados ao longo deste capítulo.

Figura 24 – Metodologia utilizada no processo de otimização inicial.



Fonte: Elaborado pela autora (2024).

Inicialmente, a pesquisa envolveu a coleta de dados, com foco na identificação dos parâmetros fundamentais relacionados ao projeto do sistema de ancoragem. Em seguida, foram analisadas as variáveis, com a definição dos objetivos do processo de otimização, a especificação das restrições e o estabelecimento dos intervalos de variação para as variáveis de projeto. Essa abordagem teve como objetivo orientar a definição do sistema de ancoragem para a plataforma em estudo.

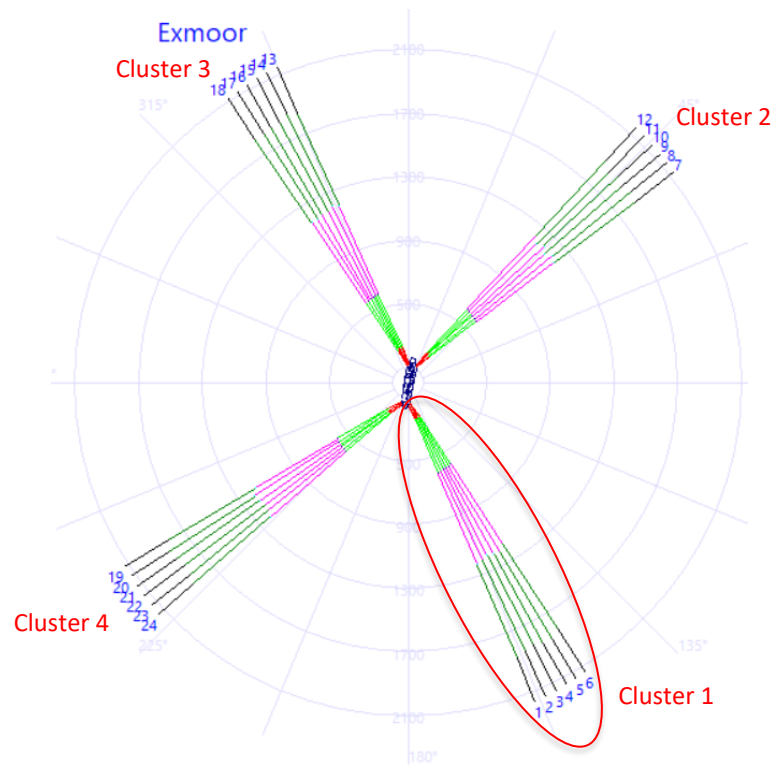
Após a síntese das informações essenciais, procedeu-se ao estudo de otimização das linhas do sistema de ancoragem da plataforma, empregando a técnica de busca e otimização por meio de um algoritmo genético (NSGA-II). Nesta etapa, o programa Synapse Offshore foi empregado, e os resultados foram devidamente analisados e tabulados. Além do Synapse Offshore, as ferramentas Dynasim e Exmoor foram utilizadas para a análise e validação dos dados.

### 3.3.1.1 *Primeira etapa do projeto do sistema de ancoragem*

O sistema de ancoragem abordado neste estudo refere-se a uma plataforma FPSO, o qual é composto por um total de 24 linhas de ancoragem. Essas linhas são

distribuídas em quatro clusters distintos, com cada agrupamento contendo seis linhas. Cabe ressaltar que as linhas são tensionadas e adotam a configuração de catenárias. A unidade apresenta 332 metros de comprimento total. A disposição geral do sistema de ancoragem é representada na Figura 25.

Figura 25 – Configuração do sistema de ancoragem.



Fonte: Programa Synapse Offshore (2024).


A plataforma possui um deslocamento de aproximadamente 400.000 toneladas, o que influencia diretamente no dimensionamento e na resistência das linhas de ancoragem. Cada linha de ancoragem possui, em média, cerca de 3050 metros de comprimento, sendo constituída por diferentes materiais distribuídos ao longo da profundidade. Aproximadamente 6% do comprimento total corresponde ao cabo de aço, localizado próximo ao fairlead, com aproximadamente 190 metros e diâmetro de 120 mm; cerca de 82% é formado por segmento de poliéster, com aproximadamente 2.500 metros e diâmetro de 206 mm; e os últimos 12%, próximos ao fundo, são compostos por amarras de aço, com comprimento médio de aproximadamente 360 metros e diâmetro também de 120 mm.

Essa configuração permite otimizar o desempenho das linhas quanto à resistência, peso submerso e flexibilidade. O cabo de aço, posicionado no topo da

linha, garante rigidez e resistência à abrasão na região do fairlead. O poliéster, componente principal da linha, oferece elevada elasticidade e leveza, características fundamentais para suportar variações dinâmicas sem comprometer a integridade da linha. Por fim, as amarras de aço, localizadas próximas ao solo marinho, proporcionam ancoragem segura e estabilidade ao sistema.

A separação desses três segmentos ao longo da linha de ancoragem é apresentada na Figura 26, que ilustra a disposição dos materiais. Essa representação facilita a visualização do arranjo e reforça a compreensão sobre a lógica construtiva adotada no projeto.

Figura 26 – Configuração da linha de ancoragem.



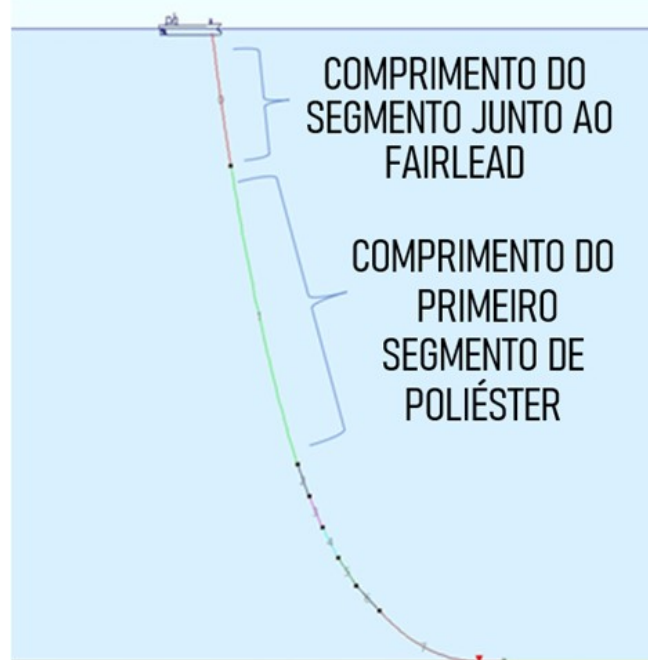
Fonte: Adaptado de Pinto (2014).

#### A. Seleção das variáveis

O raio de ancoragem das linhas do sistema foi definido como uma variável de otimização, com uma variável específica para cada agrupamento (cluster). Além disso, para cada agrupamento, considerou-se a alteração do comprimento do segmento junto ao fairlead como um segundo parâmetro a ser otimizado. Já o comprimento do primeiro segmento de poliéster foi estabelecido como a terceira variável de otimização, aplicando-se uma variável para cada linha.

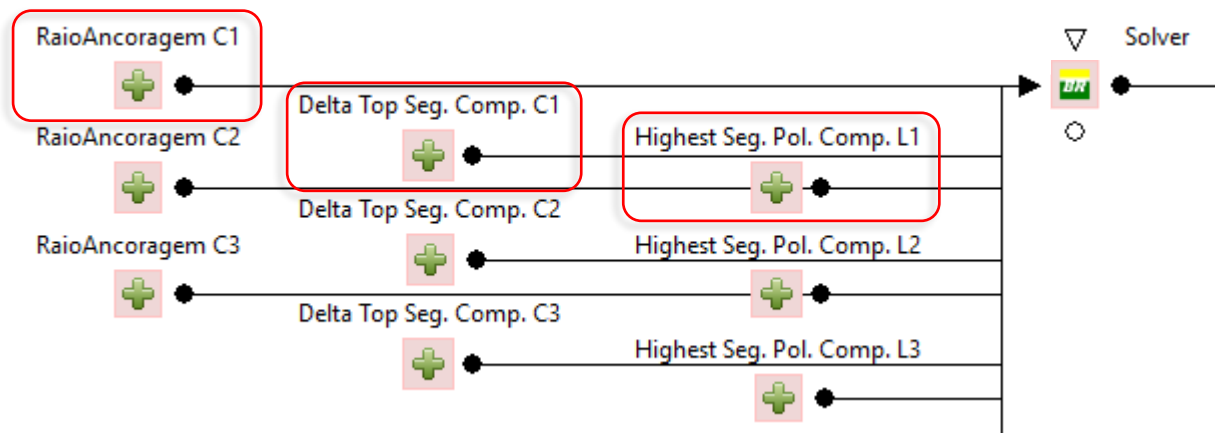
Ressalta-se que as posições das âncoras são determinadas no projeto, e a busca concentra-se na tração no topo das linhas. A Figura 27 apresenta uma representação visual dos comprimentos utilizados, facilitando sua diferenciação, enquanto a Figura 28 apresenta as variáveis fundamentais consideradas no modelo.

Figura 27 – Comprimentos das linhas de ancoragem.



Fonte: Adaptado do programa Synapse Offshore (2024).

Figura 28 – Variáveis no modelo de otimização.



Fonte: Adaptado do programa Synapse Offshore (2024).


Foi estabelecido um intervalo para as variáveis referentes ao raio de ancoragem, fixando-se o valor mínimo em 1827 metros e o máximo em 2639 metros, com uma resolução de 203 metros. Tal valor é constante para as linhas de um mesmo cluster, mas pode sofrer variações entre os diferentes clusters do sistema. Para as variáveis referentes ao comprimento do primeiro segmento junto ao fairlead, definiu-se uma variação de -24 metros a +24 metros em relação aos valores já pré-existentes no projeto inicial fornecido. A resolução adotada foi de 0,6 metros, sendo também uma variável definida por cluster.

Por fim, as variáveis que representam o comprimento do primeiro segmento de poliéster foram ajustadas no intervalo de -24 metros e 24 metros em relação aos valores pré-existentes. Diferentemente das anteriores, neste caso foi considerada uma variável por linha, sendo definida uma resolução de 0,6 metros para todas as variáveis.

### B. Função objetivo

O problema abordado neste estudo envolve um cenário de otimização, cujo objetivo principal é ajustar os parâmetros das linhas de ancoragem de modo a minimizar a porcentagem de offset a partir do neutro, promovendo uma ancoragem mais precisa e consistente com os requisitos do projeto. Na Figura 29, encontra-se representado o objetivo estabelecido no modelo de otimização desenvolvido no Synapse Offshore.

Figura 29 – Objetivo no modelo de otimização.



Fonte: Adaptado do programa Synapse Offshore (2024).

Cabe destacar que a norma ISO 19901-7 não impõe um limite único e fixo de offset para o posicionamento de unidades flutuantes. Em vez disso, ela recomenda que os limites de offset admissíveis sejam definidos com base na análise integrada entre o sistema de ancoragem e os risers, considerando as condições de projeto. De acordo com a norma, os limites máximos de offset variam conforme o tipo e a configuração dos risers.

Para risers rígidos, os valores geralmente situam-se entre 8% e 12% da profundidade d'água. Já os risers flexíveis em águas profundas costumam admitir offsets entre 10% e 15%, enquanto os risers flexíveis em águas rasas podem tolerar deslocamentos ainda maiores, entre 15% e 30%, conforme o sistema continue ancorado à estrutura.

Apesar de não haver uma exigência formal específica para as linhas de ancoragem, é comum adotar, por boas práticas de projeto, o limite conservador de 10% da profundidade d'água como valor de referência. Essa abordagem visa garantir maior segurança operacional, reduzir os riscos à integridade dos risers e prolongar a vida útil dos componentes do sistema. Além disso, o uso de margens mais restritivas favorece o atendimento aos padrões internacionais de confiabilidade, mesmo na ausência de obrigatoriedade normativa direta.

### *C. Restrições*

Em um processo de otimização, é fundamental adotar medidas que garantam tanto a eficiência quanto a segurança operacional. Para isso, destacam-se três restrições estratégicas: a limitação do delta yaw neutro, o controle da tensão nas linhas de ancoragem e a restrição da carga aplicada às âncoras.

Cada uma dessas restrições desempenha um papel importante no equilíbrio entre desempenho e segurança do sistema. Dessa forma, as restrições são expressas na sequência:

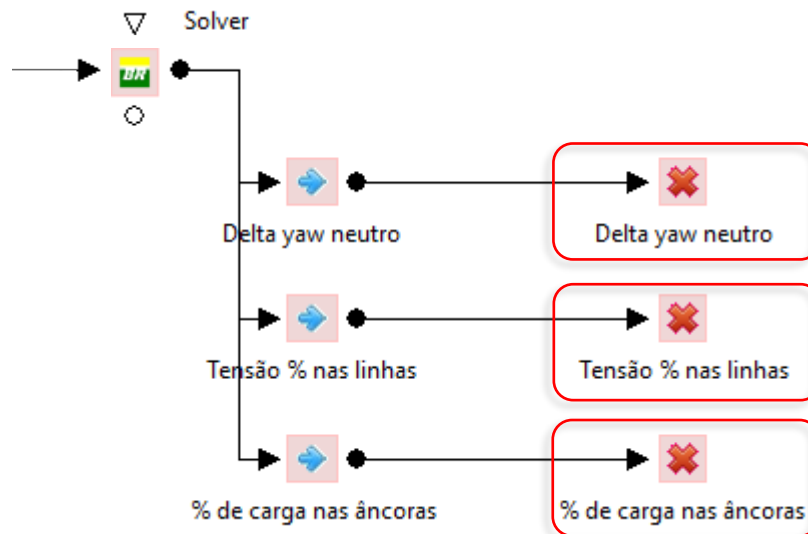
1. A restrição do delta yaw neutro, limitada a menos de 2 graus, visa garantir que o sistema de ancoragem permaneça dentro de parâmetros de projeto e normativos. Esse controle é essencial para evitar a torção indesejada nas linhas e nos risers, contribuindo assim para a eficácia do sistema.
2. Manter a tensão nas linhas de ancoragem abaixo de 60% não apenas atende às diretrizes estabelecidas pela ISO 19901-7, mas também previne sobrecargas, proporcionando uma margem de segurança substancial contra falhas e rupturas, mesmo em condições ambientais variáveis.
3. Limitar a carga nas âncoras a valores inferiores a 100%, conforme as diretrizes da norma ISO 19901-7, tem o propósito de evitar sobrecargas no sistema, prevenindo possíveis deslocamentos inesperados ou falhas nas âncoras e, dessa forma, assegurando a segurança e a integridade da plataforma ancorada.

Ao incorporar essas restrições ao processo de otimização, aprimora-se tanto a eficiência operacional das plataformas quanto a confiabilidade e a segurança das

operações. A representação visual das diretrizes adotadas está apresentada na Equação 1 e na Figura 30.

$$\text{Restrições} = \begin{cases} \theta \leq 2 \text{ graus} & (\text{Delta Yaw Neutro}) \\ T \leq 60\% & (\% \text{ de Tensão nas Linhas de Ancoragem}) \\ C \leq 100\% & (\% \text{ de Carga nas Âncoras}) \end{cases} \quad (1)$$

Figura 30 – Restrições no modelo de otimização.




Fonte: Adaptado do programa Synapse Offshore (2024).

#### D. Solver

O Dynasim é um simulador dinâmico no domínio do tempo, o qual se destaca como uma ferramenta para análises hidrodinâmicas e estruturais de sistemas navais e oceânicos, seja para cenários amarrados ou com posicionamento dinâmico (Nishimoto; Fucatu; Masetti, 2002). Devido à sua capacidade, o Dynasim é especialmente apropriado para diversas aplicações, tais como o estudo do comportamento dinâmico dos sistemas offshore, a determinação do arranjo e dimensionamento das linhas de ancoragem e dos risers, além do dimensionamento e otimização do sistema de posicionamento dinâmico, entre outras (Ferreira, 2016).

Para realizar análises precisas nessas aplicações, o software incorpora os efeitos das forças ambientais, como ondas, vento e correntes. A Figura 31 apresenta a utilização do solver Dynasim no modelo de projeto do sistema de ancoragem.

Figura 31 – Solver (Dynamisim) no modelo de otimização.



Fonte: Adaptado do programa Synapse Offshore (2024).

No âmbito do processo de otimização, o Dynamisim destaca-se como ferramenta fundamental ao ser empregado como solver dinâmico, o qual assume a função de simular numericamente problemas complexos relacionados à dinâmica do sistema de ancoragem.

Durante a execução da otimização, o Dynamisim é utilizado para simular e calcular as respostas dinâmicas do sistema, considerando uma ampla variedade de condições ambientais e diferentes configurações de linhas de ancoragem. As simulações, foram realizadas ao longo de aproximadamente três horas de processamento, adotando um tempo de corte (cutoff) de 60 segundos.

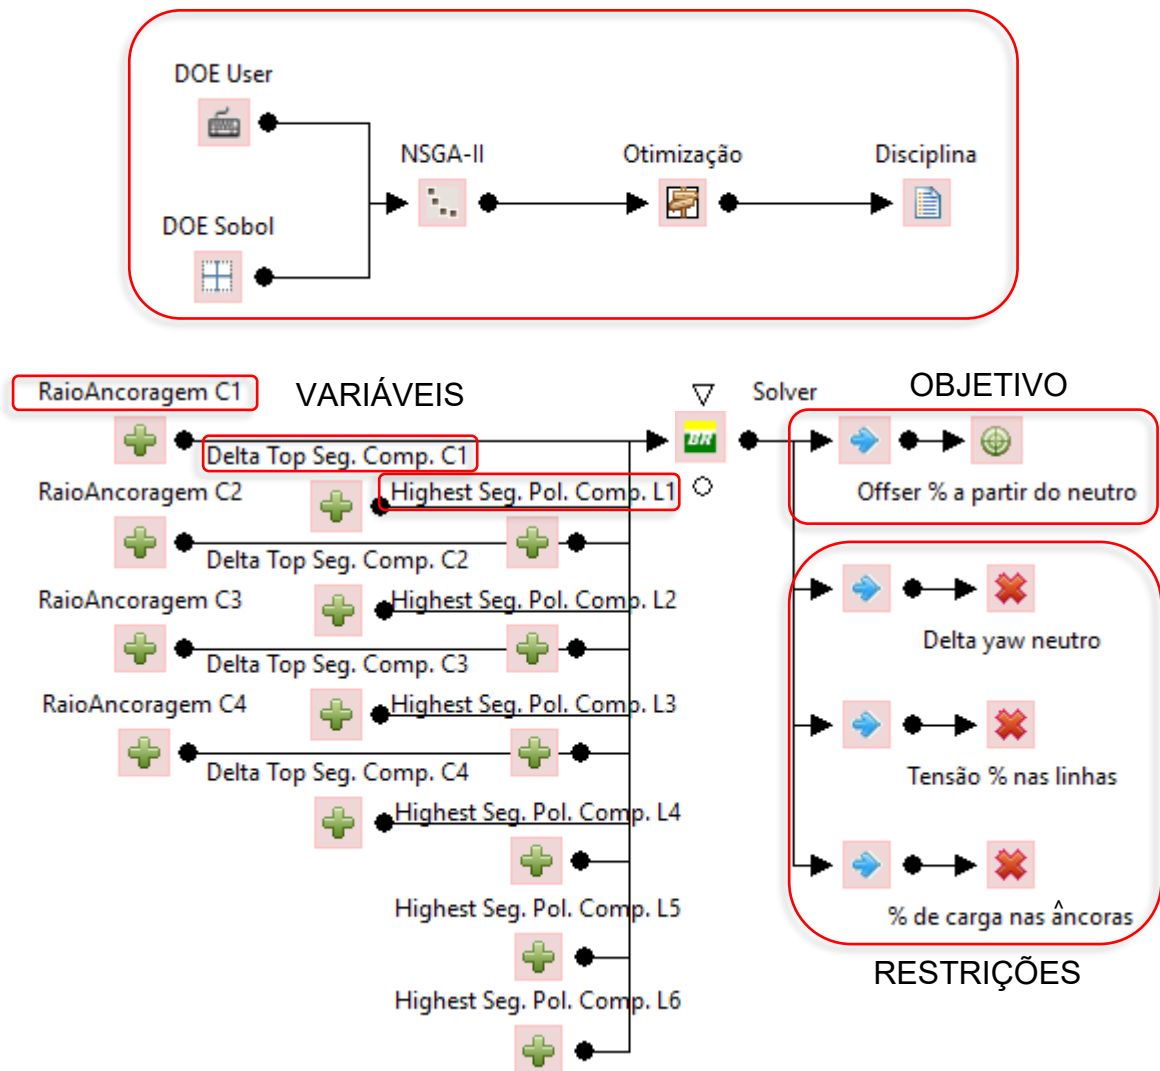
Sua contribuição é essencial para encontrar soluções numéricas que não apenas avaliam, mas também aprimoram o desempenho do sistema de ancoragem da plataforma offshore, sendo uma peça-chave na busca por configurações ideais e em conformidade com normativas.

### *E. Modelo de otimização*

Na Figura 32, são apresentadas seções do modelo de otimização desenvolvido no programa Synapse Offshore, evidenciando o objetivo, as restrições e algumas das variáveis associadas aos raios de ancoragem, aos comprimentos dos primeiros segmentos de poliéster e aos comprimentos dos segmentos junto ao fairlead, tanto para cada agrupamento quanto para todas as linhas de ancoragem do modelo, conforme a natureza de cada variável.

O modelo foi estruturado com o intuito de integrar os principais fatores que influenciam as respostas do sistema de ancoragem, de forma que se tornasse possível realizar uma avaliação simultânea e articulada das variáveis de projeto. Essa modelagem permite uma condução mais estruturada e eficiente do processo de busca por soluções ótimas, respeitando os limites técnicos estabelecidos para o comportamento da unidade.

Figura 32 – Parte do modelo de otimização.



Fonte: Adaptado do programa Synapse (2024).

## F. Otimização

Após a definição das variáveis de projeto, a formulação da função objetivo, o estabelecimento das restrições e a construção do modelo de otimização, iniciou-se a etapa de execução do processo de busca por soluções. Para essa fase, foi empregado o algoritmo genético NSGA-II, selecionado devido à sua capacidade comprovada de lidar com problemas de múltiplas variáveis e múltiplos critérios de desempenho.

A utilização do NSGA-II tem como objetivo identificar a configuração ótima do sistema de ancoragem da plataforma offshore, assegurando a geração de soluções de alta qualidade técnica e em conformidade com as normas vigentes.

### 3.3.1.2 *Segunda etapa do projeto do sistema de ancoragem*

Com o intuito de alcançar as metas estabelecidas e atender às normativas específicas, foram introduzidas modificações significativas na abordagem metodológica adotada neste estudo. Essas adaptações foram necessárias para aprimorar o controle sobre o offset a partir do neutro do sistema de ancoragem.

Nesta segunda etapa, são apresentadas as variações implementadas em relação à estratégia empregada inicialmente, concentrando-se em três variáveis específicas do projeto. As alterações realizadas buscaram refinar o desempenho global do sistema, melhorando a resposta da plataforma às forças ambientais e ajustando a distribuição de tensões nas linhas de ancoragem. Os demais elementos do processo, como objetivos, restrições e estrutura do modelo, foram preservados, assegurando a continuidade da metodologia adotada e permitindo a comparação direta entre os resultados obtidos nas diferentes fases.

#### *A. Alterações nas especificações das variáveis*

Foi observado que, para as três variáveis principais, raio de ancoragem, comprimento do segmento junto ao fairlead e comprimento do primeiro segmento em poliéster, a maioria dos valores encontrava-se no limite ou muito próxima do intervalo definido para as análises (range). Essa condição poderia comprometer a eficácia da otimização, restringindo a capacidade do algoritmo de explorar novas alternativas dentro do espaço de busca.

Diante desse cenário, na segunda etapa da análise optou-se por exportar todos os dados correspondentes à solução ótima da primeira fase, utilizando-os como novo ponto de partida para as variáveis. Essa abordagem resultou na criação de um novo arquivo de entrada no programa Dynasim, que foi incorporado ao ambiente Synapse Offshore para as análises subsequentes.

Essa estratégia permitiu ampliar o intervalo considerado para as variáveis de projeto, abrangendo novas faixas de valores em torno da solução já otimizada, ampliando assim as possibilidades de busca durante o processo. Com isso, buscou-se não apenas evitar a limitação dos valores de contorno, mas também potencializar a capacidade do algoritmo em encontrar soluções ainda mais ajustadas às exigências técnicas e operacionais do sistema de ancoragem.

É importante destacar que apenas os valores iniciais foram modificados, preservando-se os limites máximos e mínimos previamente estabelecidos para as variáveis de projeto, garantindo a comparabilidade entre as diferentes fases do estudo.

O Quadro 1 apresenta as alterações realizadas nas configurações relativas ao comprimento do segmento junto ao fairlead, e o Quadro 2, as alterações no comprimento do primeiro segmento de poliéster, facilitando a compreensão e visualização dos dados. Em ambos os quadros, constam os valores iniciais e finais das variáveis, provenientes do projeto de ancoragem, bem como os novos valores obtidos durante o processo de otimização que conduziu à solução encontrada.

Quadro 1 – Alterações no comprimento do segmento junto ao fairlead.

Comprimento do segmento junto ao fairlead					
	Valores Iniciais (m)	Novos Valores (m)		Valores Finais (m)	Novos Valores (m)
L1	131,00	107,00	L1	178,00	155,00
L2	156,00	132,60	L2	204,00	180,60
L3	186,00	162,60	L3	234,00	210,60
L4	146,00	122,60	L4	194,00	170,60
L5	126,00	102,60	L5	174,00	150,60
L6	196,00	172,60	L6	244,00	220,60
L7	156,00	132,00	L7	204,00	180,00
L8	126,00	102,00	L8	174,00	150,00
L9	196,00	172,00	L9	244,00	220,00
L10	136,00	112,00	L10	184,00	160,00
L11	191,00	167,00	L11	239,00	215,00
L12	126,00	102,00	L12	174,00	150,00
L13	166,00	142,00	L13	214,00	190,00
L14	126,00	102,00	L14	174,00	150,00
L15	171,00	147,00	L15	219,00	195,00
L16	151,00	127,00	L16	199,00	175,00
L17	176,00	152,00	L17	224,00	200,00
L18	161,00	137,00	L18	209,00	185,00
L19	181,00	157,00	L19	229,00	205,00
L20	121,00	97,00	L20	169,00	145,00
L21	141,00	117,00	L21	189,00	165,00
L22	176,00	152,00	L22	224,00	200,00
L23	161,00	137,00	L23	209,00	185,00
L24	131,00	107,00	L24	179,00	156,00

Fonte: Elaborado pela autora (2023).

Quadro 2 – Alterações no comprimento do primeiro segmento de poliéster.

Comprimento do primeiro segmento de poliéster						
	Valores Iniciais (m)	Novos Valores (m)		Valores Finais (m)	Novos Valores (m)	
P1	518,73	499,53		P1	566,73	547,53
P2	518,73	495,93		P2	566,73	543,93
P3	518,73	495,93		P3	566,73	543,93
P4	518,73	510,93		P4	566,73	558,93
P5	518,73	495,33		P5	566,73	543,33
P6	518,73	501,93		P6	566,73	549,93
P7	518,73	495,73		P7	566,73	542,73
P8	518,73	494,33		P8	566,73	543,33
P9	518,73	496,53		P9	566,73	544,53
P10	518,73	497,73		P10	566,73	545,73
P11	518,73	495,93		P11	566,73	543,93
P12	518,73	507,33		P12	566,73	555,33
P13	518,73	495,93		P13	566,73	543,93
P14	518,73	497,13		P14	566,73	545,13
P15	518,73	497,73		P15	566,73	545,73
P16	518,73	496,53		P16	566,73	544,53
P17	518,73	499,53		P17	566,73	557,53
P18	518,73	496,53		P18	566,73	544,53
P19	518,73	494,73		P19	566,73	542,73
P20	518,73	514,53		P20	566,73	562,53
P21	518,73	494,73		P21	566,73	542,73
P22	518,73	505,53		P22	566,73	553,53
P23	518,73	509,13		P23	566,73	557,13
P24	518,73	496,53		P24	566,73	544,53

Fonte: Elaborado pela autora (2023).

Observa-se no Quadro 1 que, para cada linha de ancoragem (L1, L2, L3 etc.), o valor inicial do comprimento do segmento junto ao fairlead foi substituído pelo valor indicado na coluna “Novos Valores”. A partir desse novo valor, o algoritmo de otimização passa a permitir variações de  $\pm 24$  m, em incrementos de 0,6 m, abrangendo assim uma outra faixa de possíveis configurações.

De forma análoga, o Quadro 2 apresenta os ajustes realizados no comprimento do primeiro segmento de poliéster (P1, P2, P3 etc.). Também nesse caso, os valores originais foram substituídos por novos valores de referência, que serviram como ponto central para a variação posterior no processo de otimização.

Dessa forma, os “Novos Valores” indicados nos Quadros 1 e 2 passaram a atuar como base para a segunda etapa da análise, permitindo maior flexibilidade no

modelo e viabilizando a exploração de outras configurações de ancoragem que atendam aos critérios de desempenho estabelecidos.

### *B. Otimização*

Após as adaptações mencionadas, o processo de otimização foi retomado no programa Synapse Offshore. Utilizando o novo conjunto de dados, derivado da solução ótima anterior, as variáveis passaram por uma nova fase de análise e ajuste. O algoritmo genético NSGA-II foi novamente empregado para conduzir a otimização, desta vez explorando um intervalo diferente e buscando refinamentos na configuração do sistema de ancoragem da plataforma offshore.

Essa etapa é fundamental para avaliar como as alterações nas variáveis impactam a eficiência e o desempenho do sistema, fornecendo insights valiosos para aprimorar ainda mais o projeto.

Adicionalmente, essa nova fase permite a comparação dos resultados com a configuração anterior, possibilitando modificações que podem resultar em melhor desempenho e maior segurança operacional. Os resultados obtidos também servem como base para futuras iterações, reforçando o caráter progressivo da metodologia e contribuindo para decisões de projeto mais assertivas.

#### *3.3.1.3 Terceira etapa do projeto do sistema de ancoragem*

Na busca contínua pela otimização do sistema de ancoragem, a terceira etapa deste estudo concentrou-se na implementação de ajustes estratégicos visando o aprimoramento dos resultados obtidos nas fases anteriores. Com o objetivo de atender às metas estabelecidas e manter a conformidade com as normativas vigentes, foram realizadas modificações pontuais na abordagem metodológica, voltadas para o refino das configurações obtidas.

Essa etapa enfatiza o ajuste de variáveis críticas, buscando a melhoria do desempenho geral e a eficiência do projeto, de modo a assegurar a obtenção de soluções que atendam de forma ainda mais rigorosa aos requisitos técnicos e operacionais do sistema de ancoragem projetado.

### A. Alterações nas especificações das variáveis

Inicialmente, conduziu-se uma análise semelhante à anterior para identificar possíveis limitações nos extremos dos intervalos que poderiam impactar as análises. Diferentemente da análise anterior, não foram identificados limites restritivos, visto que todas as variáveis se encontravam dentro dos intervalos definidos.

O passo subsequente consistiu na busca por uma configuração que atendesse simultaneamente às restrições e aos objetivos desejados. A solução 12479 foi identificada como a mais promissora, apresentando valores próximos ao offset desejado, embora as porcentagens de tensão nas linhas e de carga nas âncoras ainda não estivessem integralmente dentro dos limites estabelecidos.

O Quadro 3 apresenta os valores correspondentes à solução 12479, facilitando a análise detalhada dos resultados obtidos.

Quadro 3 – Solução 12479.

ID	Offset % a partir do neutro	Delta yaw neutro	Tensão % nas linhas	% de carga nas âncoras
12479	10,01%	1,54 graus	63,62%	100,05%

Fonte: Elaborado pela autora (2024).

Para corrigir essa questão, ajustaram-se os limites das variáveis no programa Synapse Offshore, utilizando os dados da solução 12479 como ponto de partida e realizando adaptações nos intervalos de busca.

Especificamente para o raio de ancoragem, os valores mínimo e máximo foram redefinidos para 1700 metros e 2100 metros, respectivamente, enquanto a resolução foi alterada de 203 metros para 19,05 metros, permitindo uma varredura mais refinada do espaço de soluções. Essas alterações estão detalhadas no Quadro 4, que apresenta os novos parâmetros adotados.

Quadro 4 – Ajustes nos limites do raio de ancoragem.

	MÍNIMO	MÁXIMO	RESOLUÇÃO
ANTERIOR	1827 metros	2639 metros	203 metros
COM AJUSTE	1700 metros	2100 metros	19,05 metros

Fonte: Elaborado pela autora (2024).

No caso do comprimento do segmento junto ao fairlead, a abordagem foi alterada de uma variável por agrupamento (cluster) para uma variável por linha, ampliando a flexibilidade do modelo.

Os limites mínimo e máximo foram redefinidos para variar entre -17 metros e +17 metros em relação aos valores da solução 12479. Além disso, a resolução foi ajustada de 0,6 metro para 0,4 metro, permitindo menores variações entre os valores possíveis. Essas modificações estão detalhadas no Quadro 5.

Quadro 5 – Ajustes nos limites do comprimento do segmento junto ao fairlead.

	MÍNIMO	MÁXIMO	RESOLUÇÃO
ANTERIOR	- 24 metros	+ 24 metros	0,6 metros
COM AJUSTE	- 17 metros	+ 17 metros	0,4 metros

Fonte: Elaborado pela autora (2024).

Em relação ao comprimento do primeiro segmento de poliéster, não foram realizadas alterações, mantendo-se todas as configurações previamente adotadas. As especificações correspondentes estão apresentadas no Quadro 6.

Quadro 6 – Ajustes nos limites do comprimento do primeiro segmento de poliéster.

	MÍNIMO	MÁXIMO	RESOLUÇÃO
SEM AJUSTES	- 24 metros	+ 24 metros	0,6 metros

Fonte: Elaborado pela autora (2024).

Os Quadros 7 e 8 apresentam as alterações realizadas nas configurações das variáveis, com o objetivo de facilitar a compreensão e visualização do processo, sendo registrados os valores das variáveis obtidas anteriormente no processo de otimização, bem como os novos valores, definidos com base na solução 12479.

Esses dados foram utilizados para a elaboração de um novo arquivo no programa Dynasim, o qual servirá como ponto de partida no Synapse Offshore para a continuidade das análises.

Dessa forma, observa-se que os valores das variáveis foram ajustados com base na solução 12479, que serviu como referência para a criação do novo arquivo de dados. Para o raio de ancoragem, o intervalo foi redefinido para variar entre 1700 e 2100 metros, com uma resolução de 19,05 metros, permitindo uma busca mais refinada do valor ideal durante o processo de otimização. Já para o comprimento do

segmento junto ao fairlead e para o comprimento do primeiro segmento de poliéster, os valores foram atualizados de modo a proporcionar uma maior discretização durante o processo de otimização.

Esses novos valores, obtidos com incrementos mais refinados, permitem uma melhor exploração das configurações do sistema de ancoragem, contribuindo para a obtenção de uma solução mais robusta e alinhada aos objetivos e restrições estabelecidos.

Dessa forma, o novo arquivo de dados no Dynasim, elaborado com essas configurações, servirá como ponto de partida para as próximas iterações no programa Synapse Offshore.

Quadro 7 – Alterações no comprimento do segmento junto ao fairlead.

Comprimento do segmento junto ao fairlead					
	Valores Iniciais (m)	Novos Valores (m)		Valores Iniciais (m)	Novos Valores (m)
L1	107,00	106,40	L1	155,00	154,40
L2	132,60	129,60	L2	180,60	177,60
L3	162,60	159,60	L3	210,60	207,60
L4	122,60	119,60	L4	170,60	167,60
L5	102,60	99,60	L5	150,60	147,60
L6	172,60	169,60	L6	220,60	217,60
L7	132,00	138,00	L7	180,00	186,00
L8	102,00	108,00	L8	150,00	156,00
L9	172,00	178,00	L9	220,00	226,00
L10	112,00	118,00	L10	160,00	166,00
L11	167,00	173,00	L11	215,00	221,00
L12	102,00	108,00	L12	150,00	156,00
L13	142,00	148,60	L13	190,00	196,60
L14	102,00	108,60	L14	150,00	156,60
L15	147,00	153,60	L15	195,00	201,60
L16	127,00	133,60	L16	175,00	181,60
L17	152,00	158,60	L17	200,00	206,60
L18	137,00	143,60	L18	185,00	191,60
L19	157,00	156,40	L19	205,00	204,40
L20	97,00	96,40	L20	145,00	144,40
L21	117,00	116,40	L21	165,00	164,40
L22	152,00	151,40	L22	200,00	199,40
L23	137,00	136,40	L23	185,00	184,40
L24	107,00	106,40	L24	155,00	154,40

Fonte: Elaborado pela autora (2024).

Quadro 8 – Alterações no comprimento do primeiro segmento de poliéster.

Comprimento do primeiro segmento de poliéster						
	Valores Iniciais (m)	Novos Valores (m)		Valores Iniciais (m)	Novos Valores (m)	
P1	499,53	501,33		P1	547,53	549,33
P2	495,93	493,53		P2	543,93	541,53
P3	495,93	496,53		P3	543,93	544,53
P4	510,93	516,93		P4	558,93	564,93
P5	495,33	513,33		P5	543,33	561,33
P6	501,93	502,53		P6	549,93	550,53
P7	494,73	495,33		P7	542,73	543,33
P8	495,33	513,93		P8	543,33	561,93
P9	496,53	502,53		P9	544,53	550,53
P10	497,73	492,33		P10	545,73	540,33
P11	495,93	499,53		P11	543,93	547,53
P12	507,33	498,93		P12	555,33	546,93
P13	495,93	510,93		P13	543,93	558,93
P14	497,13	508,53		P14	545,13	556,53
P15	497,73	495,93		P15	545,73	543,93
P16	496,53	490,53		P16	544,53	538,53
P17	499,53	494,73		P17	547,53	542,73
P18	496,53	498,93		P18	544,53	546,93
P19	494,73	491,73		P19	542,73	539,73
P20	514,53	522,93		P20	562,53	570,93
P21	494,73	501,93		P21	542,73	549,93
P22	505,53	500,13		P22	553,53	546,13
P23	509,13	516,33		P23	557,13	564,33
P24	496,53	504,93		P24	544,53	552,93

Fonte: Elaborado pela autora (2024).

### B. Otimização

Na terceira etapa, ajustes específicos foram implementados nas configurações do sistema de ancoragem, com foco nas variáveis de projeto previamente redefinidas. Utilizando o algoritmo genético NSGA-II, procedeu-se à exploração do novo intervalo de busca, com o objetivo de identificar uma configuração capaz de manter a porcentagem de offset a partir do neutro abaixo de 10%. Importante destacar que, apesar das modificações nas variáveis, as restrições e os objetivos do projeto foram integralmente preservados, garantindo a consistência metodológica. Como resultado, o processo de otimização foi concluído, resultando em uma solução que atende aos requisitos estabelecidos.

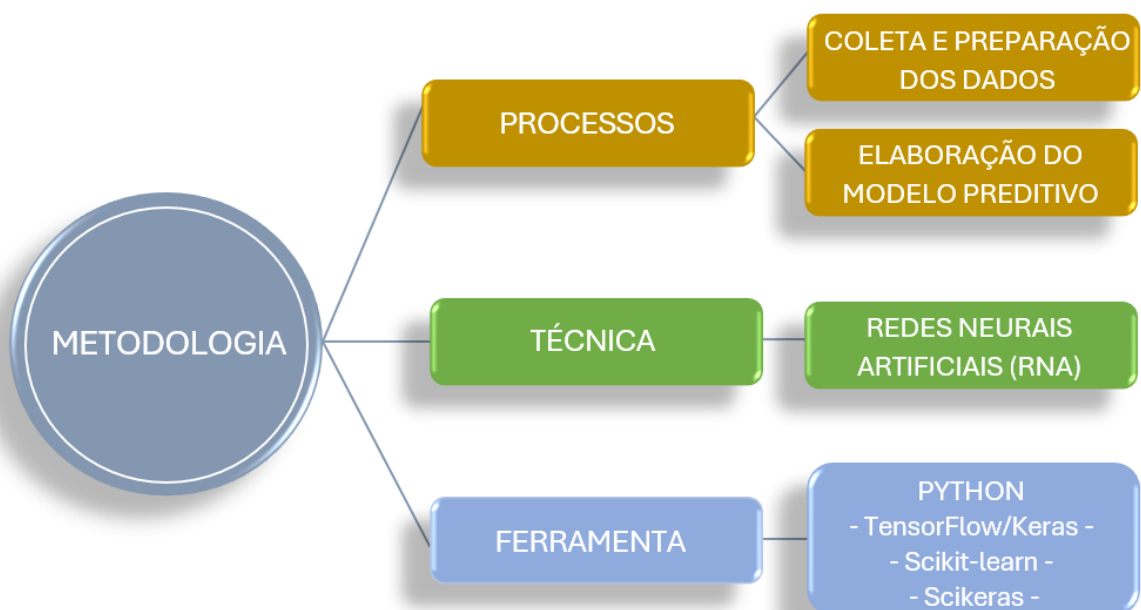
### 3.3.2 Aplicação de redes neurais no processo de otimização

Considerando as limitações observadas no tempo computacional necessário para simulações dinâmicas e a crescente demanda por modelos com maior capacidade de resposta computacional no ambiente offshore, a aplicação de redes neurais artificiais (RNAs) emergiu como uma solução estratégica para complementar e potencializar o processo de otimização do sistema de ancoragem.

Nesta etapa, o foco recai sobre a construção de modelos preditivos baseados em RNAs, com o objetivo de reduzir o número de simulações diretas com o solver Dynasim e, conseqüentemente, diminuir o custo computacional associado às análises. A adoção de técnicas de inteligência artificial viabiliza a geração de modelos capazes de estimar com boa acurácia variáveis críticas do sistema a partir de dados de entrada selecionados, mantendo a fidelidade dos resultados.

A Figura 33 apresenta o procedimento inicial adotado para a criação do modelo preditivo baseado em redes neurais artificiais, oferecendo uma visão geral da metodologia aplicada, desde a preparação dos dados até a implementação final da rede. Essa representação gráfica permite compreender a lógica e o encadeamento das etapas executadas, que serão descritas detalhadamente nas subseções a seguir.

Figura 33 – Metodologia utilizada para elaboração do modelo de redes neurais.



Fonte: Elaborado pela autora (2024).

No segundo estágio da metodologia, a ênfase se direciona à aplicação de redes neurais artificiais com o objetivo de acelerar o processo de otimização do sistema de ancoragem. Essa etapa teve início com a coleta e a preparação dos dados, visando à identificação dos parâmetros fundamentais para a construção de um modelo preditivo adaptado às particularidades do sistema analisado.

Em seguida, construiu-se um modelo preditivo por meio de redes neurais artificiais, projetado para prever, individualmente, a porcentagem de offset a partir do neutro, a porcentagem de tensão nas linhas, a porcentagem de carga aplicada e o ângulo delta yaw neutro, por meio de quatro modelos independentes.

A integração desse modelo ao processo de otimização anterior representa uma abordagem híbrida e avançada, que alia a capacidade exploratória dos algoritmos à eficiência preditiva das RNAs, promovendo ganhos significativos em tempo de execução e viabilidade computacional.

A ferramenta Python foi utilizada para a implementação da rede neural, devido à sua compatibilidade com o Synapse Offshore e à sua ampla biblioteca de suporte para modelagem e treinamento de RNAs. O desenvolvimento do modelo visou especificamente a redução do tempo de processamento nas análises subsequentes, sem comprometer a precisão dos resultados obtidos.

Para a construção do modelo preditivo, utilizou-se o conjunto de dados obtido nas etapas anteriores de simulação, contendo as variáveis de entrada e suas respectivas saídas. A seguir, são detalhadas as etapas desse processo, incluindo a seleção e o pré-processamento dos dados, a definição da arquitetura da rede neural, o treinamento do modelo e a avaliação do seu desempenho preditivo.

### **3.3.2.1**      *Modelo preditivo utilizando redes neurais artificiais*

A etapa subsequente ao processo de otimização consiste na aplicação de redes neurais artificiais (RNAs) para aprimorar o desempenho do sistema, reduzindo o tempo de processamento associado às simulações completas. Para isso, os dados gerados ao longo das etapas anteriores foram organizados em uma nova base consolidada, contendo as variáveis de entrada e as quatro principais variáveis de saída a serem previstas.

Duas abordagens principais foram consideradas quanto à topologia da rede: o uso de uma única rede neural com múltiplas saídas e a construção de redes independentes, cada uma voltada à previsão de uma única variável de saída.

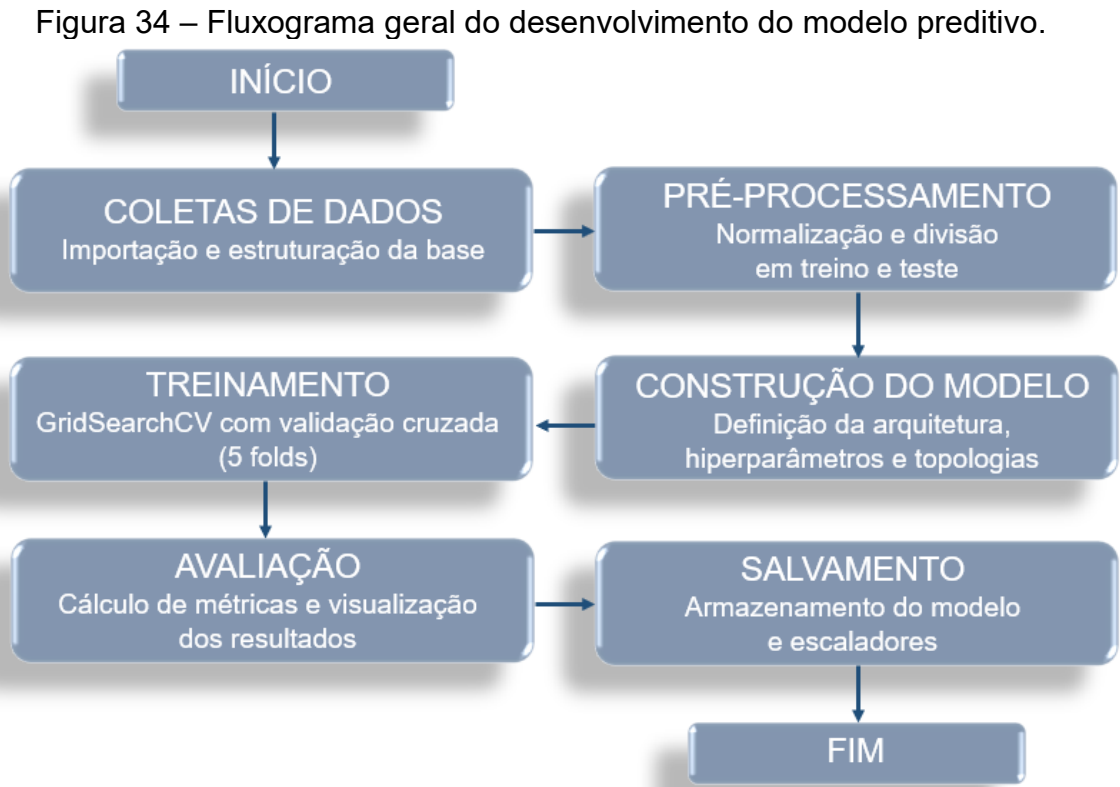
A literatura aponta que, embora redes com múltiplas saídas possam capturar relações cruzadas entre variáveis, elas exigem maior esforço de ajuste e apresentam maior risco de overfitting quando as saídas apresentam comportamentos estatísticos distintos (Standley et al., 2020). Diante disso, optou-se pela segunda abordagem, a construção de quatro redes neurais independentes, permitindo não apenas configurar hiperparâmetros e topologias específicas conforme a complexidade de cada saída, mas também facilitar a análise de desempenho individual e a replicação dos modelos, já que cada estrutura pode ser avaliada e ajustada separadamente.

Cada rede neural foi projetada para prever uma das seguintes variáveis: offset a partir do neutro, tensão nas linhas, carga nas âncoras e ângulo delta yaw neutro. As variáveis de entrada incluem parâmetros geométricos do sistema de ancoragem, como os raios de ancoragem (R), comprimentos dos primeiros segmentos de poliéster (P) e os comprimentos dos segmentos junto ao fairlead (L). Essas entradas foram utilizadas de forma consistente entre os modelos, garantindo comparabilidade dos resultados.

Embora existam quatro códigos distintos, a estrutura de cada um é essencialmente semelhante, diferenciando-se apenas pela variável-alvo prevista e pela configuração dos hiperparâmetros. Essa modularidade permite adaptar a arquitetura da rede conforme a complexidade e a sensibilidade de cada saída, otimizando o desempenho individual.

Em função desta padronização estrutural, apresenta-se no Apêndice A apenas o código referente à previsão do offset, que é representativo das demais implementações.

Na Figura 34, observa-se um fluxograma geral do processo de construção dos modelos preditivos baseados em redes neurais artificiais, abrangendo desde a coleta e preparação dos dados até as etapas de treinamento, validação e salvamento final do modelo.



Fonte: Elaborado pela autora (2024).

O desenvolvimento do modelo preditivo teve início com a importação das bibliotecas essenciais para o processo. Foram utilizadas as bibliotecas Pandas e Numpy para a manipulação e estruturação dos dados, Scikit-learn para as etapas de normalização e avaliação, e TensorFlow/Keras para a construção e o treinamento da rede neural. Essa organização inicial garante que o ambiente esteja devidamente preparado para todas as fases do fluxo de trabalho, contribuindo para a clareza, manutenção e replicabilidade do código.

Adicionalmente, visando assegurar a reprodutibilidade dos resultados, as seeds do Numpy, do TensorFlow e da biblioteca random foram fixadas. Essa prática evita variações aleatórias entre diferentes execuções do modelo, permitindo que os experimentos apresentem consistência e que os resultados sejam comparáveis entre diferentes testes e versões do modelo (Géron, 2019).


Em seguida, os dados foram carregados a partir de um arquivo CSV contendo as informações necessárias para a predição. Cada um dos quatro modelos desenvolvidos neste trabalho é responsável por prever uma variável distinta: offset a partir do neutro, delta yaw neutro, tensão nas linhas e carga nas âncoras.

Após a definição das variáveis de entrada e saída, os dados foram normalizados e, em seguida, divididos em dois subconjuntos: 80% para treinamento e 20% para teste, utilizando a função `train_test_split`. Esse conjunto de teste foi mantido separado durante toda a fase de ajuste do modelo, sendo utilizado exclusivamente para a avaliação final do desempenho.

Para o processo de ajuste dos hiperparâmetros e validação do modelo, foi utilizada a classe `GridSearchCV` da biblioteca `Scikit-learn`, a qual realiza internamente uma validação cruzada K-Fold com 5 divisões (folds). Embora o código não implemente diretamente o particionamento manual dos dados em folds, a validação cruzada é automaticamente conduzida pelo `GridSearchCV`, que aplica o K-Fold apenas ao conjunto de treinamento.

Dessa forma, o conjunto de teste permaneceu inteiramente separado, sendo utilizado exclusivamente para a avaliação final do melhor modelo. Essa estratégia, conhecida como validação cruzada com hold-out externo, é amplamente reconhecida na literatura por melhorar a avaliação do modelo, reduzindo o viés e aumentando a robustez dos resultados (Kuhn & Johnson, 2013; Géron, 2019). A Figura 35 ilustra esse processo.

Figura 35 – Divisão dos dados em conjuntos de treinamento e teste.



Fonte: Elaborado pela autora (2024).

A busca pelos melhores hiperparâmetros foi realizada de forma exaustiva, testando todas as combinações possíveis entre os valores definidos em uma malha (grid). Foram avaliadas diferentes topologias de rede, variando o número de camadas ocultas (2 a 4), o número de neurônios por camada (32, 64 e 128), taxas de dropout (0.05 e 0.1), coeficientes de regularização L2 (0.00001 e 0.0001) e taxas de aprendizado (0.005 e 0.001).

O Quadro 9 apresenta a combinação dessas configurações estruturais testadas. Vale destacar que os hiperparâmetros e topologias apresentados no Quadro 9 referem-se exclusivamente ao modelo preditivo da variável offset a partir do neutro. Para as demais, foram testadas outras combinações de hiperparâmetros, conforme a complexidade e o comportamento estatístico específico de cada variável.

Quadro 9 – Hiperparâmetros e topologias testadas no GridSearchCV.

Hiperparâmetros	Valores
Nº de camadas ocultas	2,3,4
Nº de neurônios/camada	32, 64, 128
Dropout	0.05, 0.1
Regularização L2	0.00001, 0.0001
Taxa de aprendizado	0.005, 0.001
Otimizador	Adam (fixo)
Épocas	350 (fixo)
Batch size	32,64,128

Fonte: Elaborado pela autora (2024).

Para lidar com as diferenças de escala entre as variáveis, foi aplicada a normalização utilizando o MinMaxScaler, que transforma os dados em valores no intervalo [0, 1]. Essa etapa é representada na Figura 36. Em redes neurais, essa prática é fundamental para garantir que todas as variáveis de entrada contribuam de maneira equilibrada durante a retropropagação, evitando que variáveis com maior magnitude dominem o gradiente.

Além disso, a normalização tende a acelerar a convergência dos algoritmos de otimização, como Adam ou RMSProp, resultando em menor tempo de treinamento e maior estabilidade dos pesos (Géron, 2019). O escalador foi ajustado (método fit) exclusivamente sobre os dados de treinamento e posteriormente aplicado (método transform) aos dados de teste, evitando vazamento de informação.

Figura 36 – Normalização com MinMaxScaler.



Fonte: Elaborado pela autora (2024).

A construção do modelo preditivo foi baseada em uma função customizada que gera uma rede neural do tipo fully connected (MLP). Essa abordagem permite personalizar os principais hiperparâmetros da arquitetura, como o número de neurônios por camada, a quantidade de camadas ocultas, a taxa de dropout, o coeficiente de regularização L2, a taxa de aprendizado e a escolha do otimizador. A decisão de empregar uma rede neural densa deve-se à capacidade de tais arquiteturas em capturar relações complexas entre variáveis, sobretudo quando os dados podem conter interações não lineares (Goodfellow et al., 2016).

Para controlar a complexidade do modelo e evitar overfitting, foram incorporadas técnicas de regularização L2 (weight decay), que penalizam grandes valores de peso (Krogh; Hertz, 1992), e camadas de Dropout, que desativam aleatoriamente um percentual de neurônios durante o treinamento, promovendo generalização (Srivastava et al., 2014).

A função de ativação ReLU (Rectified Linear Unit) foi adotada em todas as camadas ocultas por sua eficiência em mitigar problemas de gradientes pequenos observados em funções ativadoras saturadas, como a Sigmoid (Glorot et al., 2011), contribuindo para treinos mais rápidos e eficazes em redes profundas. Além disso, foram incluídas camadas de Batch Normalization para estabilizar as distribuições internas das ativações, reduzindo o internal covariate shift e favorecendo a convergência (Ioffe; Szegedy, 2015).

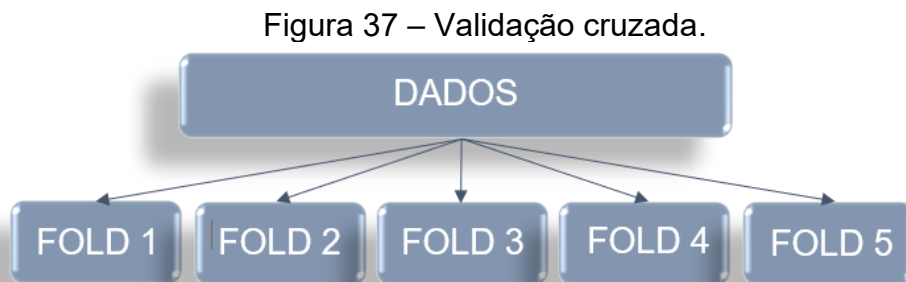
Durante o treinamento, foram implementados dois callbacks: o EarlyStopping e o ReduceLROnPlateau. O primeiro callback monitora a perda no conjunto de treinamento (loss) e interrompe o processo quando não há evolução significativa, considerando que a validação já é realizada internamente durante a busca por hiperparâmetros. O segundo callback atua sobre a taxa de aprendizado (learning rate), reduzindo-a gradualmente quando o modelo apresenta estagnação no desempenho.

Essa redução progressiva permite ajustes mais sutis dos pesos nas fases finais do treinamento, favorecendo a convergência a mínimos locais mais adequados. Ambas as estratégias são amplamente adotadas em redes neurais por contribuírem para maior estabilidade do treinamento e por evitarem tanto o overfitting quanto o underfitting em contextos com elevado número de épocas ou dados complexos (Bergstra; Bengio, 2012).

A otimização dos hiperparâmetros foi realizada por meio do GridSearchCV, integrado ao Keras por meio do wrapper KerasRegressor, fornecido pela biblioteca Scikeras, que permite a integração entre Keras e a API de busca da biblioteca Scikit-learn. Essa abordagem sistemática combinou a busca exaustiva por diferentes combinações de parâmetros (número de neurônios, profundidade da rede, taxas de dropout, regularização e taxa de aprendizado) com a validação cruzada do tipo K-Fold com cinco divisões (folds), aplicada exclusivamente ao conjunto de treinamento.

Em cada uma das cinco iterações (folds), o conjunto de treinamento é subdividido em diferentes partições para treino e validação interna, permitindo que cada subconjunto seja utilizado como validação uma vez. Esse processo é automatizado pelo GridSearchCV, que avalia o desempenho médio de cada configuração testada com base na métrica  $R^2$ .

A Figura 37 ilustra esse procedimento. Ao final do processo, é selecionada a configuração de hiperparâmetros que apresentou o melhor desempenho médio. Essa metodologia melhora a robustez da análise e reduz a dependência de uma única divisão dos dados, promovendo maior confiabilidade na seleção do modelo final.




Fonte: Elaborado pela autora (2024).

Concluídas as etapas de treinamento e validação, os dados de teste, que foram mantidos completamente separados do processo de validação cruzada e ajuste de hiperparâmetros, foram submetidos à mesma normalização aplicada aos dados de treinamento, utilizando os escaladores previamente ajustados. Essa abordagem assegura a consistência no pré-processamento e previne qualquer forma de vazamento de dados, o que poderia comprometer a integridade da avaliação final.

Com o modelo otimizado e os dados de teste preparados, foram então realizadas as previsões, utilizando exclusivamente o melhor estimador selecionado pelo GridSearchCV. Para quantificar a precisão do modelo, foram calculadas três métricas estatísticas fundamentais (Figura 38): o coeficiente de determinação ( $R^2$ ), que expressa a proporção da variância da variável de saída explicada pelas variáveis de entrada; o erro quadrático médio (MSE), sensível a grandes desvios e útil para penalizar erros de maior magnitude; e o erro absoluto médio (MAE), que oferece uma medida intuitiva do desvio médio entre os valores previstos e os reais. Essas métricas são amplamente utilizadas na literatura para avaliar a qualidade preditiva de modelos (Hyndman; Athanasopoulos, 2018).

Figura 38 – Métricas estatísticas fundamentais.



Fonte: Elaborado pela autora (2024).

A análise dessas métricas fornece uma visão abrangente da qualidade preditiva do modelo, enquanto a comparação gráfica entre os valores reais e previstos, com destaque para as primeiras amostras do conjunto de teste, permite visualizar o comportamento do modelo em termos de possíveis padrões de superestimação ou subestimação. Essa etapa é fundamental para verificar a aderência da rede neural ao comportamento real do sistema modelado, complementando a avaliação numérica com uma interpretação visual dos resultados.

Em seguida, o modelo otimizado foi salvo utilizando a função específica do Keras, possibilitando sua reutilização em aplicações futuras sem a necessidade de novo treinamento. Paralelamente, os escaladores utilizados na normalização também foram armazenados, garantindo que quaisquer novas amostras passem pelo mesmo mapeamento aplicado durante o aprendizado, fator essencial para a consistência das previsões.

Cada etapa do processo, desde o pré-processamento dos dados (com normalização e divisão), passando pela construção e treinamento da rede neural, até a avaliação e o salvamento do modelo, foi cuidadosamente estruturada para assegurar a implementação de um sistema preditivo robusto, eficiente e facilmente replicável.

Essa metodologia também se mostrou suficientemente versátil para atender às outras três variáveis-alvo: delta yaw neutro, tensão nas linhas e carga nas âncoras. As diferenças entre os modelos residem exclusivamente na variável de saída e nos hiperparâmetros ajustados para cada caso, assegurando que cada rede neural seja especializada na previsão de sua respectiva variável-alvo.

### **3.3.3 Otimização do sistema de ancoragem utilizando o modelo preditivo**

Nesta terceira etapa, foi conduzido um novo estudo de otimização, no qual o modelo preditivo baseado em redes neurais artificiais passou a ser utilizado em substituição ao solver Dynasim. Essa abordagem teve como principal objetivo reduzir o tempo computacional das análises, mantendo a confiabilidade nos resultados e o atendimento às restrições previamente estabelecidas.

O procedimento metodológico adotado nesta etapa é sintetizado na Figura 39, que representa o fluxo geral do processo e indica as técnicas e ferramentas aplicadas em cada fase. Ressalta-se que, para cada uma das quatro variáveis de saída, foram desenvolvidos modelos preditivos independentes, treinados individualmente e com topologias específicas. Essa abordagem permitiu ajustar os hiperparâmetros de maneira personalizada, melhorando o desempenho de cada modelo em sua respectiva tarefa de predição.

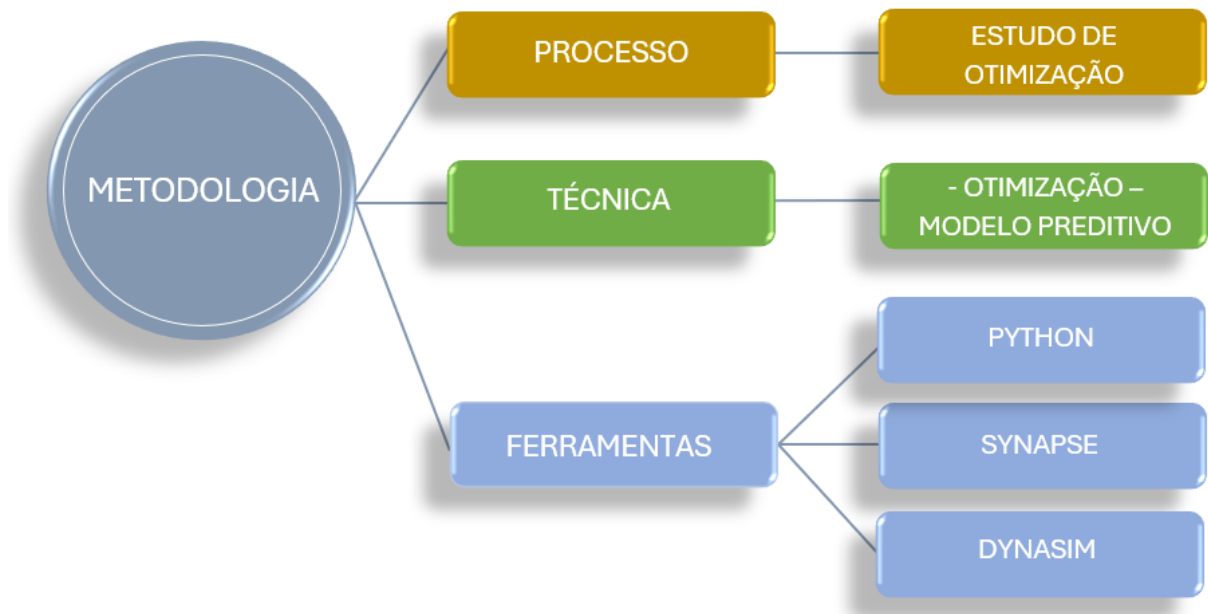
A integração do modelo preditivo ao ambiente de otimização permitiu a realização de iterações mais rápidas, uma vez que as previsões das variáveis de saída, como offset, delta yaw neutro, tensão nas linhas e carga nas âncoras, passaram a ser obtidas diretamente a partir das redes treinadas, dispensando a necessidade de simulações completas no Dynasim. Essa substituição viabilizou uma análise mais ágil de diferentes configurações de projeto, contribuindo para o refino do sistema de ancoragem.

Essa estratégia de substituição do modelo de simulação por um modelo preditivo treinado com base nos mesmos dados é reconhecida na literatura como

uma abordagem eficaz para problemas de otimização computacionalmente custosos, sendo especialmente vantajosa em contextos onde as simulações são complexas, demoradas ou economicamente inviáveis (Sun et al., 2019).

Desse modo, a terceira etapa marca a aplicação prática do modelo preditivo dentro do processo de otimização, demonstrando sua viabilidade, eficiência e valor agregado ao projeto do sistema de ancoragem. A metodologia aplicada nesta fase também reforça a importância da integração entre inteligência artificial e algoritmos evolutivos na resolução de problemas complexos na engenharia offshore.

Figura 39 – Metodologia para a otimização com a integração do modelo preditivo.



Fonte: Elaborado pela autora (2024).

Na implementação prática, a ferramenta Python foi empregada para operacionalizar os modelos preditivos, garantindo compatibilidade com os requisitos do programa Synapse. Nesse ambiente, o modelo de otimização foi reconstruído de maneira semelhante à estrutura desenvolvida no Synapse Offshore, assegurando consistência na lógica e nos parâmetros utilizados.

Após cada execução do processo de otimização, os resultados obtidos pelas redes neurais foram validados por meio de simulações no programa Dynasim, com o objetivo de verificar se o comportamento predito estava de acordo com os limites estabelecidos para offset, tensão nas linhas, carga nas âncoras e ângulo delta yaw neutro.

Essa etapa de verificação contínua foi essencial para garantir a confiabilidade dos modelos e permitiu ajustes finos sempre que necessário, assegurando a fidelidade das previsões aos critérios técnicos definidos. Dessa forma, consolidou-se a eficácia do modelo preditivo como ferramenta de apoio à tomada de decisão no projeto de sistemas de ancoragem offshore.

### 3.3.3.1 Construção do modelo no programa Synapse

A construção do modelo no programa Synapse baseou-se nos dados obtidos nas etapas anteriores, permitindo a representação detalhada do sistema de ancoragem, incluindo a definição das restrições, variáveis de entrada e objetivos da otimização. O ambiente gráfico e modular do Synapse viabilizou a configuração completa do modelo, integrando variáveis de projeto como o raio de ancoragem, o comprimento do segmento junto ao fairlead e o comprimento do primeiro segmento de poliéster.

Para a geração inicial dos pontos de amostragem, utilizou-se exclusivamente o DOE Sobol, devido à sua capacidade de distribuir pontos de forma equidistante e abrangente no espaço de projeto. Essa característica é representada na Figura 40. A opção DOE User não foi necessária, uma vez que não houve a necessidade de inserir manualmente os valores das variáveis. O DOE Sobol gerou automaticamente 10 pontos amostrais, permitindo uma varredura inicial eficiente das possíveis configurações do sistema.

O algoritmo de otimização NSGA-II, previamente empregado nas etapas iniciais do projeto, foi mantido sem alterações nesta fase, preservando sua configuração e parâmetros de operação. Em seguida, prosseguiu-se com o procedimento de otimização e por fim, a disciplina, que corresponde ao modelo completo de otimização a ser resolvido.

Figura 40 – Etapa inicial do modelo de otimização utilizando o modelo preditivo.

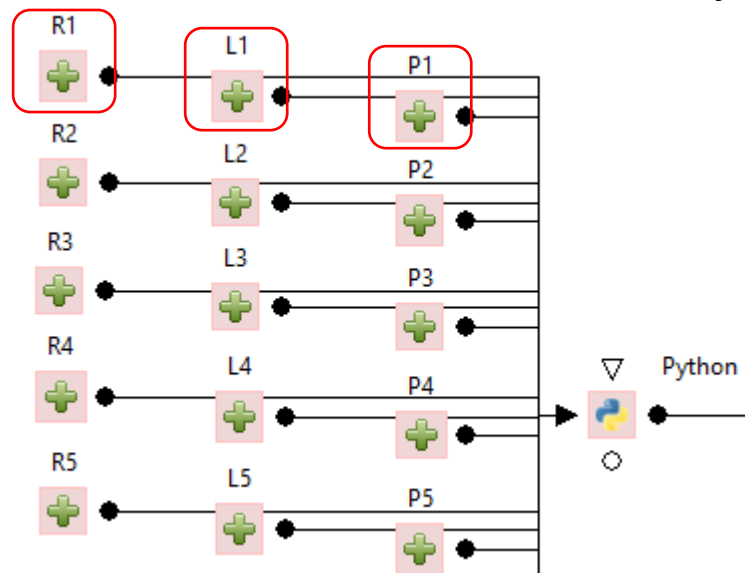


Fonte: Elaborado pela autora (2024).

Para a definição das variáveis de entrada no modelo, foram mantidas as especificações adotadas no projeto inicial. As variáveis identificadas como “R” correspondem aos raios de ancoragem, as variáveis “L” referem-se à variação do comprimento do segmento junto ao fairlead, e as variáveis “P” representam a variação do comprimento do primeiro segmento de poliéster.

Cada categoria inclui 24 variáveis, totalizando 72 variáveis de projeto utilizadas na nova configuração do modelo de otimização. A disposição das variáveis no ambiente do Synapse, bem como sua organização no modelo de otimização, está representada na Figura 41.

Figura 41 – Variáveis utilizadas no modelo de otimização.



Fonte: Elaborado pela autora (2024).

Inicialmente, os limites e as resoluções definidos para as variáveis de projeto empregadas na otimização com o modelo preditivo estão organizados no Quadro 10, conforme apresentado a seguir.

Quadro 10 – Limites e resoluções das variáveis.

	MÍNIMO	MÁXIMO	RESOLUÇÃO
Raio de Ancoragem	1827 metros	2639 metros	203 metros
Variação do comprimento do segmento junto ao fairlead	-24 metros	+24 metros	0,6 metros
Variação do comprimento do primeiro segmento de poliéster	-24 metros	+24 metros	0,6 metros

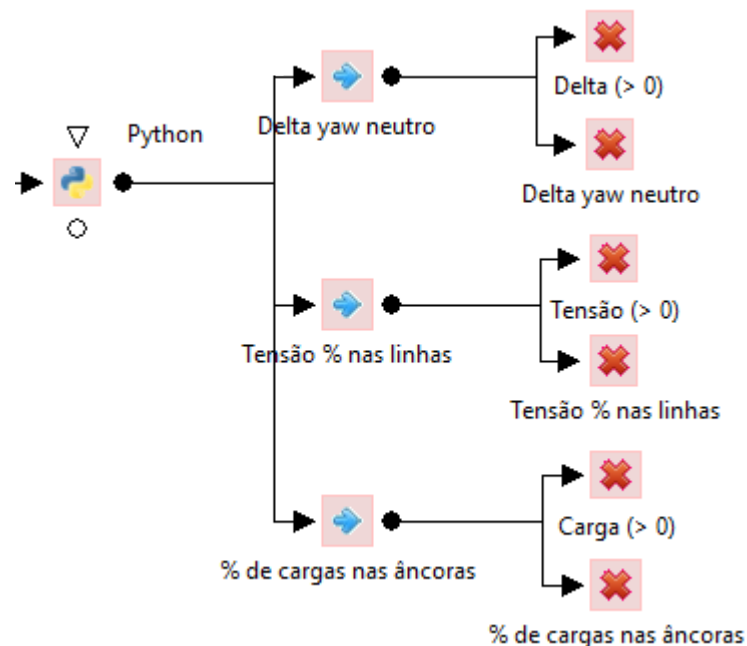
Fonte: Elaborado pela autora (2024).

As três restrições principais foram mantidas: a restrição do delta yaw neutro, limitada a menos de 2 graus; a manutenção da tensão nas linhas de ancoragem abaixo de 60% e, por fim, a limitação da carga nas âncoras a valores inferiores a 100%. Entretanto, como o modelo original de otimização não previa limites inferiores explícitos, observou-se a ocorrência de valores negativos durante o processo de busca, o que não condiz com a realidade física do sistema.

Para mitigar esse problema, foram incluídas três restrições adicionais que asseguram que os valores das três saídas (delta yaw neutro, tensão nas linhas e carga nas âncoras) sejam estritamente positivos. Essa medida visa preservar a consistência física das soluções e evitar instabilidades durante a execução da otimização, sem modificar a estrutura geral do modelo preditivo.

A Figura 42 apresenta as restrições aplicadas no modelo de otimização com redes neurais, evidenciando tanto os limites superiores previamente definidos quanto as novas restrições inferiores inseridas.

Figura 42 – Restrições aplicadas no modelo de otimização.




Fonte: Elaborado pela autora (2024).

O objetivo do modelo preditivo permaneceu inalterado: minimizar a porcentagem de offset a partir do neutro, sendo esse critério representado na Figura 43. Além disso, foi incorporada uma restrição adicional que impõe um valor mínimo estritamente positivo para o offset, ou seja, exige que o valor permaneça sempre

acima de zero. Essa restrição foi introduzida com o intuito de eliminar soluções não factíveis, nas quais o offset poderia assumir valores negativos. Com essa medida, além de assegurar a coerência dos resultados, também se obtém maior eficiência computacional, uma vez que soluções inviáveis são descartadas precocemente durante o processo de busca, reduzindo o tempo total de análise.

Figura 43 – Objetivo aplicado no modelo de otimização.



Fonte: Elaborado pela autora (2024).

Como solver, foi utilizado o Python, que desempenha a função de carregar os modelos preditivos previamente treinados e salvos, bem como realizar novas previsões a partir dos dados gerados no ambiente do Synapse. Para garantir organização e clareza na execução, o código foi estruturado em duas partes distintas: a primeira voltada à preparação do ambiente de inferência, e a segunda dedicada à geração das previsões propriamente ditas.

A primeira parte, considerada o código de preparação, é responsável pela importação das bibliotecas necessárias, carregamento dos dados, definição dos modelos salvos e identificação das colunas de entrada utilizadas durante o treinamento. São utilizadas bibliotecas fundamentais para a manipulação de dados, execução das previsões e garantia de consistência com o processo de aprendizado anterior.

A biblioteca Pandas é empregada para manipulação de estruturas tabulares, enquanto o Numpy possibilita a realização eficiente de operações matemáticas vetorizadas. O módulo Sklearn.preprocessing fornece os métodos de normalização por meio do MinMaxScaler, assegurando que os dados de entrada estejam na mesma escala aplicada durante o treinamento.

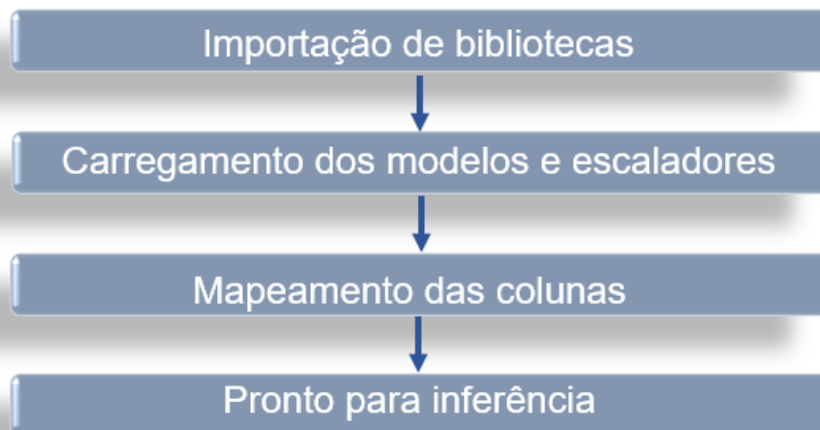
Além disso, a biblioteca Joblib é utilizada para carregar os escaladores previamente salvos, garantindo que novas amostras passem pelas mesmas transformações aplicadas ao conjunto de treino. Os modelos de rede neural são carregados com o método `load_model` da biblioteca `Tensorflow.keras.models`,

permitindo a reutilização direta das redes já treinadas, sem necessidade de reprocessamento. Esses procedimentos asseguram que a etapa de inferência mantenha total conformidade com os padrões estabelecidos durante o desenvolvimento e validação dos modelos.

Ao final, define-se uma lista de identificadores de colunas que mapeia corretamente as variáveis de entrada para suas respectivas posições na matriz de dados. Essa correspondência é essencial para garantir que os dados sejam interpretados pelo modelo exatamente como foram utilizados durante o treinamento. Dessa forma, o código inicial configura integralmente o ambiente para que os modelos preditivos operem de forma precisa, recebendo dados escalonados e gerando previsões coerentes.

O trecho do código de preparação encontra-se descrito no Apêndice B, enquanto o fluxo lógico correspondente a essa etapa é apresentado na Figura 44.

Figura 44 – Fluxograma da primeira parte do código.



Fonte: Elaborado pela autora (2024).

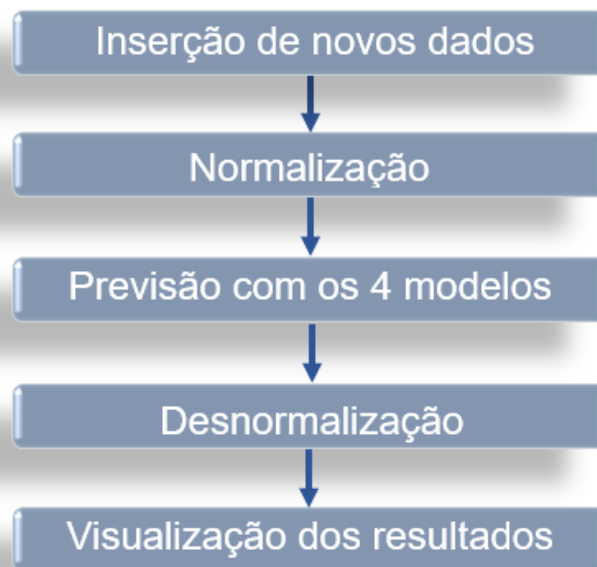
Na segunda parte do código, prossegue-se com a definição dos valores de entrada, os quais são organizados em um DataFrame de acordo com as colunas previamente definidas durante o processo de treinamento. Em seguida, esses dados são normalizados com o uso dos escaladores previamente carregados, garantindo que as entradas estejam na mesma escala empregada durante o ajuste dos modelos preditivos.

Com os dados de entrada devidamente escalonados, o código realiza as previsões para cada uma das quatro variáveis de saída de forma independente,

utilizando os modelos de rede neural carregados na etapa anterior. Após a predição, os valores obtidos são desnormalizados, ou seja, convertidos de volta à sua escala original, facilitando a interpretação e a análise prática dos resultados.

Ao final da execução, os valores previstos são apresentados de forma organizada, permitindo a análise crítica e a verificação da adequação dos resultados gerados. A implementação detalhada dessa segunda parte do código encontra-se descrita no Apêndice C, enquanto seu funcionamento está representado de forma esquemática na Figura 45.

Figura 45 – Fluxograma da segunda parte do código.



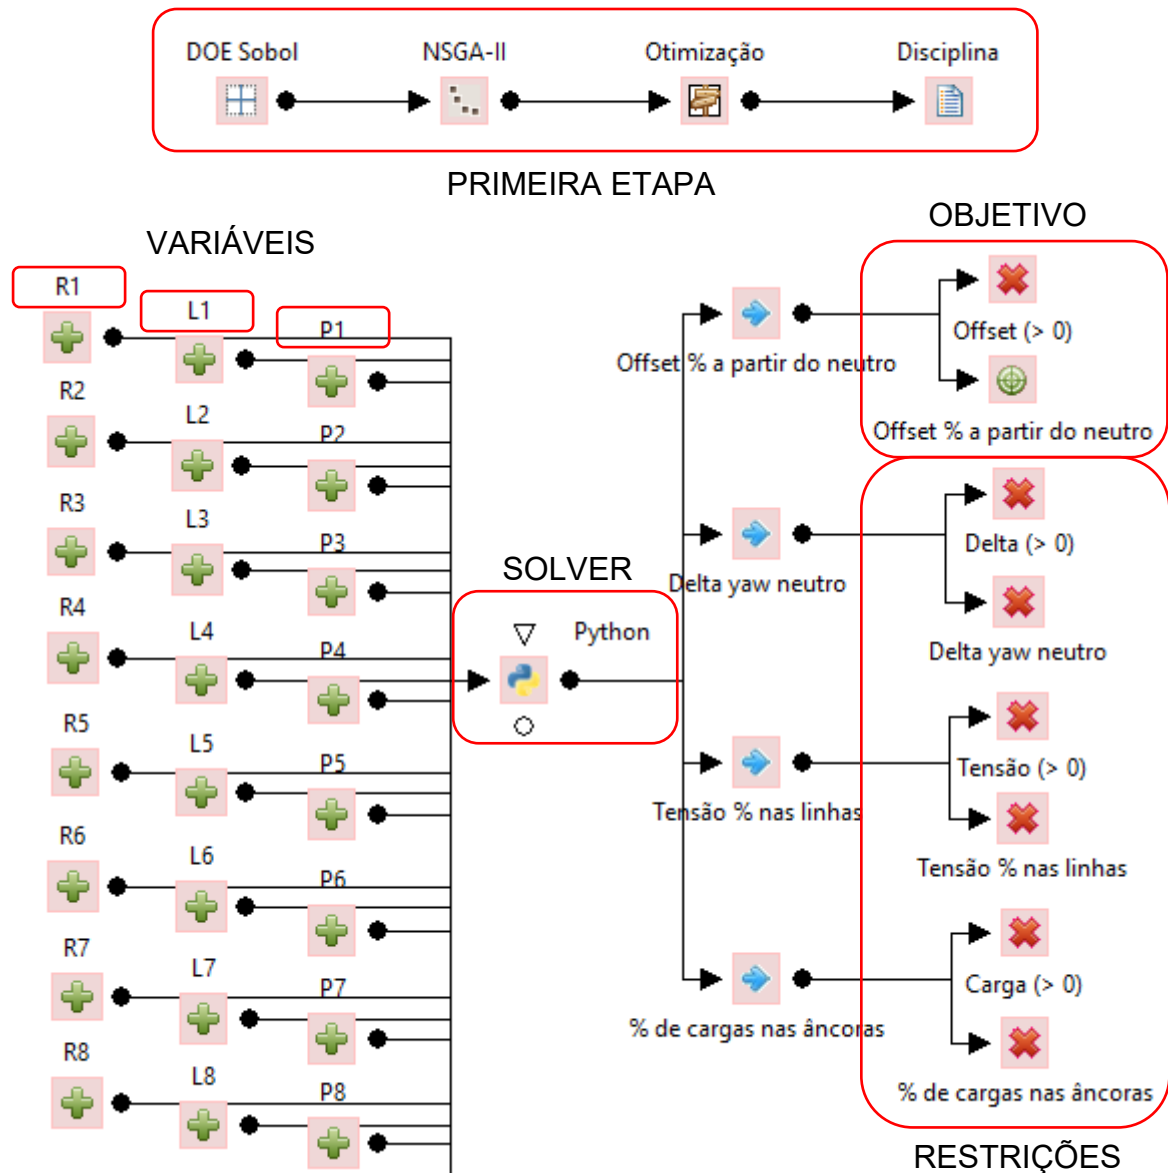
Fonte: Elaborado pela autora (2024).

Finalizadas essas etapas, a Figura 46 apresenta um trecho do modelo final implementado no Synapse, evidenciando a integração entre as variáveis de entrada, os objetivos, as restrições e a aplicação do modelo preditivo executado via Python. Essa visualização reforça a aplicação prática da abordagem desenvolvida e sua efetiva incorporação ao processo de otimização do sistema de ancoragem.

Além de demonstrar a comunicação entre os componentes do modelo, a figura evidencia como o Synapse foi configurado para acionar os scripts em Python como solver externo, permitindo o processamento em tempo real das estimativas realizadas por meio das redes neurais previamente treinadas.

Essa integração automatizada possibilita uma avaliação eficiente de múltiplas combinações de variáveis durante a busca pela melhor configuração do sistema, assegurando precisão, redução de tempo computacional e aderência aos critérios de projeto previamente definidos.

Figura 46 – Modelo final no programa Synapse.



Fonte: Elaborado pela autora (2024).

### 3.3.3.2 Primeira etapa do processo de otimização com o modelo preditivo

Nesta etapa, foi realizada a primeira análise com o objetivo de verificar se as soluções geradas pelo modelo preditivo estavam em conformidade com as

restrições previamente definidas, bem como com a recomendação técnica para a porcentagem de offset a partir do neutro. Para essa verificação, utilizou-se o programa Dynasim, no qual foram inseridas as 72 variáveis de cada solução: 24 correspondentes ao raio de ancoragem, 24 à variação do segmento junto ao fairlead e 24 à variação do primeiro segmento de poliéster. Em seguida, foram avaliados os quatro parâmetros de saída: porcentagem de offset a partir do neutro, porcentagem de tensão nas linhas, porcentagem de carga nas âncoras e delta yaw neutro, com o intuito de comparar os valores previstos pela rede neural com os valores reais simulados.

Embora o modelo preditivo tenha sido desenvolvido com base em um conjunto extenso de dados, contendo 11659 soluções, o processo de verificação manual no Dynasim mostrou-se bastante demorado. Por esse motivo, foi possível coletar apenas 100 soluções para avaliação. Apesar dessa quantidade ser significativamente menor que o total, ela se revelou suficiente para identificar padrões de erro, avaliar a fidelidade do modelo e promover ajustes finos voltados à melhoria do desempenho preditivo.

Esse procedimento de validação manual desempenha um papel fundamental na etapa de integração entre o modelo preditivo e o processo de otimização, pois permite verificar se a substituição do solver por uma rede neural preserva os critérios de confiabilidade exigidos em aplicações. Além disso, a identificação de discrepâncias pontuais possibilita intervenções específicas na arquitetura da rede ou no conjunto de dados de treinamento, contribuindo para o aprimoramento contínuo da metodologia proposta.

### 3.3.3.3 *Segunda etapa do processo de otimização com o modelo preditivo*

Após a conclusão da primeira etapa, os resultados ainda apresentavam erros relativamente elevados e discrepâncias consideráveis em relação aos valores reais verificados no programa Dynasim. Diante desse cenário, foi implementado um processo de ajuste fino com o objetivo de aumentar a acurácia do modelo preditivo e melhorar sua capacidade de generalização.

Esse refino foi realizado a partir do modelo previamente treinado, sem a necessidade de reinicialização dos pesos, permitindo a preservação do conhecimento adquirido anteriormente. Para isso, o modelo neural salvo e os

respectivos escalonadores (MinMaxScaler de entrada e saída) utilizados na etapa anterior foram carregados, assegurando consistência no tratamento dos dados e no ambiente de treinamento.

Nesta fase, optou-se por atribuir maior relevância às novas amostras, consideradas mais representativas das regiões de interesse da busca por soluções. Essa priorização foi viabilizada por meio da técnica de ponderação de amostras com o parâmetro `sample_weight`, no qual cada uma das novas soluções recebeu peso 10, enquanto as amostras anteriores mantiveram peso 1. Essa abordagem permitiu concentrar o processo de aprendizado nas regiões críticas, sem replicar fisicamente os dados, o que contribuiu para manter a eficiência computacional e evitar o desequilíbrio do conjunto de treinamento.

Com as ponderações definidas, o modelo foi recompilado utilizando uma taxa de aprendizado reduzida para 0,0005, valor escolhido para permitir refinamentos mais precisos sem comprometer a convergência. A nova etapa de treino foi conduzida com validação cruzada interna e o uso de callbacks como `EarlyStopping` e `ReduceLROnPlateau`, os quais contribuíram para interromper o treinamento em momento oportuno e refinar a convergência sem induzir overfitting. Os resultados obtidos após o ajuste mostraram uma melhora significativa nos indicadores de desempenho, com redução nos erros (MAE e MSE) e aumento no coeficiente de determinação ( $R^2$ ), validando a eficácia da estratégia adotada.

Após a seleção das novas 100 soluções, foi realizada uma nova verificação no programa Dynasim. Embora os resultados ainda não estivessem totalmente alinhados com os valores reais ou dentro dos limites restritivos estabelecidos, verificou-se um avanço considerável em relação à etapa anterior. Houve uma redução expressiva nos valores previstos, resultando em um erro geral significativamente menor. Esse progresso demonstrou que o ajuste fino contribuiu efetivamente para o aprimoramento do modelo, ainda que etapas adicionais de refino sejam necessárias.

#### 3.3.3.4 *Terceira etapa do processo de otimização com o modelo preditivo*

Na terceira etapa, foi realizada uma verificação abrangente das restrições e limitações associadas às variáveis de entrada e saída do modelo preditivo. Durante essa análise, constatou-se que alguns limites previamente definidos e considerados

no treinamento original não estavam sendo efetivamente considerados nas soluções geradas. Essa inconsistência indicava uma possível divergência entre o espaço de busca definido no modelo de otimização e o domínio efetivo de validade do modelo preditivo.

Diante desse cenário, optou-se por revisar e atualizar as restrições aplicadas no Synapse, adotando limites mais amplos e tecnicamente representativos para cada variável de entrada. O objetivo foi assegurar que o espaço de busca estivesse alinhado aos critérios operacionais, às condições reais do sistema e aos dados disponíveis, conforme apresentado no Quadro 11. A comparação entre os valores anteriores e os atuais evidencia a ampliação dos limites e o refinamento da resolução adotada. Essa redefinição permitiu evitar extrapolações indevidas e garantiu que as soluções geradas permanecessem dentro do domínio efetivo de aprendizado do modelo preditivo, aumentando a confiabilidade dos resultados.

Quadro 11 – Novos limites e resoluções das variáveis.

VARIÁVEL	TIPO DE VALOR	MÍNIMO	MÁXIMO	RESOLUÇÃO
Raio de Ancoragem	Valor Anterior	1827 m	2639 m	203 m
	Valor Atual	1700 m	2639 m	10 m
Variação do comprimento do segmento junto ao fairlead	Valor Anterior	-24 m	+24 m	0,6 m
	Valor Atual	-24 m	+24 m	0,2 m
Variação do comprimento do primeiro segmento de poliéster	Valor Anterior	-24 m	+24 m	0,6 m
	Valor Atual	-24 m	+24 m	0,6 m

Fonte: Elaborado pela autora (2024).

As novas restrições foram devidamente implementadas no modelo do Synapse, e com elas foi possível gerar um novo conjunto de 100 soluções, agora integralmente compatíveis com o domínio de viabilidade atualizado. Para a avaliação dessas soluções, foi utilizada a versão ajustada do modelo preditivo desenvolvida na etapa anterior, sem a necessidade de um novo processo de ajuste fino ou retreinamento.

Os resultados dessas novas soluções foram analisados no programa Dynasim, onde foi possível verificar uma redução significativa nos erros em comparação às etapas anteriores. As quatro variáveis de saída apresentaram

valores bastante próximos àqueles previstos pelo modelo, o que demonstrou que as modificações nas restrições foram eficazes para alinhar melhor o espaço de busca aos resultados esperados. Mesmo sem a necessidade de retreinamento, o modelo manteve um bom desempenho diante das novas condições impostas.

#### *3.3.3.4.1 Quarta etapa do processo de otimização com o modelo preditivo*

A quarta etapa consistiu na realização de um novo ajuste fino, a partir da constatação de que os valores previstos pelo modelo estavam significativamente mais próximos dos valores reais, com erros relativamente menores do que aqueles observados nas etapas anteriores. Nesse contexto, buscou-se aprimorar ainda mais a acurácia do modelo, incorporando um conjunto de dados ampliado e atualizado.

Para esta etapa, foram utilizados um total de 300 dados: os 100 dados da primeira etapa, os 100 dados anteriormente utilizados no ajuste fino da segunda etapa e mais 100 dados novos obtidos posteriormente, todos respeitando as restrições atualizadas das variáveis de entrada. Esses novos dados foram considerados mais representativos do comportamento real do sistema, por refletirem com maior precisão as condições operacionais impostas.

A estratégia adotada envolveu a utilização conjunta desses dados no reprocessamento do modelo, priorizando o aprendizado com base nas informações mais recentes. Dessa forma, os 200 dados novos contribuíram de maneira mais efetiva para o ajuste, enquanto os 100 dados já conhecidos foram mantidos no conjunto de treinamento para reforçar padrões previamente validados. Como todos os dados estavam contidos no novo espaço de busca, foi possível realizar o ajuste fino considerando a mesma importância para cada amostra, assegurando um treinamento balanceado e sem viés para conjuntos mais antigos ou mais recentes.

O modelo preditivo previamente ajustado foi carregado, juntamente com os mesmos escalonadores de entrada e saída utilizados anteriormente, e recompilado com uma taxa de aprendizado reduzida para 0,0001. O processo de ajuste fino foi conduzido com a aplicação de técnicas como EarlyStopping e ReduceLRonPlateau, a fim de evitar overfitting e promover a estabilidade do treinamento. Ao final da etapa, observou-se uma melhora adicional nos resultados, com nova redução dos erros e maior aderência entre os valores previstos e os valores obtidos nas simulações.

No entanto, apesar da evolução significativa nos resultados, ainda não foi possível identificar uma solução que atendesse simultaneamente a todas as restrições estabelecidas no estudo. Isso indicou a necessidade de uma quinta etapa, voltada para um novo refino do modelo e uma nova tentativa de obtenção de soluções viáveis dentro do espaço restritivo proposto.

#### 3.3.3.4.2 *Quinta etapa do processo de otimização com o modelo preditivo*

Dando continuidade ao processo, a quinta etapa teve como objetivo refinar ainda mais o modelo preditivo e, finalmente, obter uma solução que atendesse integralmente às quatro restrições propostas. Para isso, foi realizado um novo ajuste fino com a incorporação de um conjunto de dados mais robusto e abrangente.

Nesta etapa, foram utilizados 400 dados no total: os 300 dados previamente utilizados nas etapas anteriores, todos já dentro das restrições atualizadas, e mais 100 novos dados, obtidos a partir da ampliação das soluções geradas após a quarta etapa. Esses 100 dados mais recentes foram incluídos para enriquecer ainda mais o aprendizado do modelo.

O ajuste fino foi realizado utilizando todos os dados de forma conjunta, com pesos iguais entre as amostras, uma vez que todo o conjunto estava alinhado às novas restrições e apresentava confiabilidade. O modelo anteriormente ajustado foi novamente carregado e recompilado a taxa de aprendizado de 0.0001. A manutenção desse valor nas etapas finais deve-se à estabilidade observada na convergência, dispensando nova redução. Além disso, mantendo a aplicação das técnicas de EarlyStopping e ReduceLRonPlateau para garantir estabilidade e evitar sobreajuste durante o treinamento. Esses parâmetros foram definidos diretamente no código, visando promover estabilidade e evitar o sobreajuste durante o treinamento.

Ao final do processo, observou-se uma nova melhora nos resultados, com os valores previstos pelo modelo apresentando alta aderência aos valores reais. A partir desse novo modelo ajustado, foram geradas e avaliadas novas soluções no programa Dynasim, culminando na identificação de uma solução viável, que atendia de forma satisfatória a todas as restrições estabelecidas: delta yaw neutro inferior a 2 graus; porcentagem de tensão nas linhas inferior a 60%; porcentagem de carga

nas âncoras inferior a 100%; e, como recomendação adicional, porcentagem de offset a partir do neutro inferior a 10%.

Esses resultados confirmam a eficácia do processo de refinamento progressivo do modelo preditivo, demonstrando que a incorporação gradual de dados mais representativos e a adaptação do espaço de busca foram essenciais para a obtenção de uma solução técnica e operacionalmente satisfatória.

Cabe destacar que o modelo preditivo original não foi substituído ou modificado em sua estrutura base ao longo das etapas. Em vez disso, foram aplicadas melhorias sucessivas por meio de ajustes finos, com a incorporação de dados cada vez mais representativos. Essa abordagem permitiu preservar o conhecimento previamente aprendido pelo modelo, ao mesmo tempo em que refinava sua capacidade de generalização frente às novas restrições e condições operacionais.

Durante esse processo, o desempenho do modelo foi continuamente monitorado a cada nova etapa, com o objetivo de evitar perda de desempenho ou esquecimento de padrões previamente aprendidos. Os resultados progressivos demonstraram que os ajustes sucessivos contribuíram para o aprimoramento do modelo, sem prejuízo ao aprendizado já consolidado.

## **4 RESULTADOS**

Neste capítulo, são apresentados os resultados obtidos a partir da aplicação da metodologia proposta, estruturada em três etapas principais. A primeira etapa consistiu no processo de otimização do sistema de ancoragem. A segunda etapa abordou o desenvolvimento e a avaliação do modelo preditivo, baseado em redes neurais artificiais, com foco na capacidade de generalização e precisão do modelo frente aos dados simulados. Por fim, a terceira etapa integrou o modelo preditivo ao processo de otimização, com o objetivo de reduzir o tempo de análise e identificar soluções viáveis de forma mais eficiente. Os desdobramentos e as melhorias observadas ao longo de cada fase são discutidos a seguir, com base em métricas de desempenho, qualidade das previsões e atendimento às restrições técnicas estabelecidas para o sistema de ancoragem.

### **4.1 RESULTADOS DO PROCESSO DE OTIMIZAÇÃO**

Os resultados obtidos ao longo das diferentes etapas do processo de otimização foram organizados de forma segmentada, de modo a permitir uma análise aprofundada e individualizada de cada fase. Essa estrutura facilita a compreensão da contribuição específica de cada etapa para o desempenho final do sistema de ancoragem, além de evidenciar os avanços progressivos alcançados com a implementação da metodologia. A seguir, são detalhados os principais resultados referentes às etapas iniciais e aos ajustes sucessivos, demonstrando a evolução obtida ao longo do processo.

#### **4.1.1 Resultados da primeira etapa do processo de otimização**

Inicialmente, a Figura 47 apresenta os resultados obtidos na primeira execução do processo de otimização proposto neste estudo. No entanto, é importante destacar que a representação gráfica contempla apenas uma fração do total de variáveis analisadas, devido à complexidade e à elevada dimensionalidade do problema. A visualização fornece, portanto, uma perspectiva parcial do comportamento das soluções, não sendo suficiente, por si só, para refletir a totalidade do processo de otimização das linhas de ancoragem de uma plataforma.

Considerando o grande número de variáveis e restrições envolvidas, torna-se necessário complementar essa análise com outras abordagens, que permitam uma compreensão mais abrangente e detalhada do sistema em estudo. Ainda assim, essa imagem é de grande importância, pois permite visualizar diretamente como o processo de otimização está sendo conduzido dentro do programa Synapse Offshore, oferecendo uma representação prática da aplicação do modelo.

Figura 47 – Resultados iniciais do processo de otimização.


ID	Viável	Erro	Ótimo	Offset [%]	Delta [graus]	Tensão [%]	Carga [%]	R1	R2	R3	R4	R5	R6
1	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	12.9879	0.4587	64.6430	99.1929	1820	1820	1820	1820	1820	1820
2	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	11.5806	0.6553	63.9372	104.7595	1910	1910	1910	1910	1910	1910
3	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	13.0349	1.4083	74.1090	120.8973	1955	1865	1955	1865	1955	1865
4	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	9.8448	2.2719	74.6528	126.4413	1865	1955	1865	1955	1865	1955
5	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	13.5396	0.3195	68.6209	111.9075	1888	1888	1932	1842	1978	1978
6	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	10.4382	0.3789	80.3874	121.7148	1978	1978	1842	1932	1888	1888
7	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	10.5116	1.8693	77.8342	131.5039	1932	1842	1888	1888	1842	1932
8	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	10.5175	0.2196	68.5064	119.5386	1842	1932	1978	1978	1932	1842
9	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	11.3024	0.2587	66.8257	114.3638	1854	1876	1876	1944	1921	1854
10	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	11.8421	1.9779	91.0772	151.0409	1944	1966	1966	1854	1831	1944
11	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	11.2361	1.6926	78.6360	135.2527	1943	1849	1968	1832	1925	1901
12	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	11.2607	0.7108	77.4562	128.0618	1866	1850	1901	1877	1917	1918
13	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	10.9532	0.2949	73.2964	112.5463	1916	1910	1845	1849	1985	1900
14	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	12.5082	2.8977	72.5296	115.7699	1903	1993	1905	1973	1975	1954
15	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	11.5768	0.3343	86.2049	144.4086	1883	1843	1841	1987	1989	1970

Fonte: Adaptado do programa Synapse Offshore (2023).

Durante o processo de otimização, o objetivo principal foi a minimização da porcentagem de offset a partir do neutro, respeitando simultaneamente três restrições críticas previamente estabelecidas: o limite do delta yaw neutro, a tensão nas linhas de ancoragem e a carga aplicada às âncoras. Para acompanhar o desempenho do modelo ao longo das iterações, foi utilizado um gráfico que representa a evolução da porcentagem de offset a partir do neutro em função do número de iterações, conforme ilustrado na Figura 48.

Nesse gráfico, cada ponto corresponde a uma solução gerada durante o processo de busca. As soluções são classificadas como viáveis (verde) ou inviáveis (vermelho), com base no atendimento às restrições definidas no modelo de otimização. Essa distinção visual entre as soluções permite verificar não apenas a tendência de melhoria dos resultados ao longo das iterações, mas também a proporção de soluções que efetivamente atendem aos critérios técnicos do projeto.

Figura 48 – Porcentagem de offset a partir do neutro em função das iterações.



A solução ótima identificada para o processo de otimização apresentou os resultados consolidados no Quadro 12 e representam a melhor solução encontrada dentro do espaço de busca considerado, respeitando todas as restrições definidas no modelo.

Quadro 12 – Resultados da primeira análise.

PRIMEIRA ANÁLISE				
VIÁVEL	Offset % a partir do neutro	Delta yaw neutro	Tensão % nas linhas	% de carga nas âncoras
VERDADEIRO	16,38 %	0,1 graus	59,03%	92,42%

Fonte: Elaborado pela autora (2023).

Embora tenha sido identificada uma solução ótima que atende plenamente às três restrições preestabelecidas, relacionadas ao delta yaw neutro, à tensão nas linhas de ancoragem e à carga nas âncoras, é importante destacar que o valor de offset a partir do neutro, registrado em 16,38%, excede o limite máximo recomendado de 10% para o posicionamento da plataforma.

Assim, embora tecnicamente viável do ponto de vista estrutural e operacional, a solução não atende ao critério adicional relacionado ao offset

admissível, que é comumente adotado como referência em projetos offshore para assegurar maior estabilidade e segurança. Diante desse cenário, torna-se necessário reavaliar a solução atualmente considerada ótima.


Com o objetivo de garantir conformidade com os parâmetros operacionais desejados, foram implementados ajustes no processo de otimização, direcionando o foco para a obtenção de soluções que, além de atenderem às restrições essenciais, também respeitem o limite para o offset.

#### 4.1.2 Resultados da segunda etapa do processo de otimização

Após a identificação de limitações na etapa anterior, especialmente no que se refere ao critério recomendado para o offset, uma nova rodada de otimização foi conduzida com ajustes no modelo e no espaço de busca.

A Figura 49 apresenta a evolução da porcentagem de offset a partir do neutro ao longo das iterações realizadas durante a segunda etapa. Cada ponto representado no gráfico corresponde a uma solução gerada pelo modelo, sendo classificado como viável (verde) ou inviável (vermelho) com base no atendimento simultâneo às restrições impostas.

Figura 49 – Porcentagem de offset a partir do neutro em função das iterações.



Fonte: Elaborado pela autora (2023).

Ao final da segunda etapa do processo de otimização, foram obtidos resultados significativamente mais próximos dos parâmetros recomendados, demonstrando avanços em relação à solução anterior.

A nova solução ótima identificada apresentou os resultados consolidados no Quadro 13, os quais indicam uma evolução importante na busca por soluções mais alinhadas aos requisitos operacionais da plataforma.

Quadro 13 – Resultados da segunda análise.

SEGUNDA ANÁLISE				
VIÁVEL	Offset % a partir do neutro	Delta yaw neutro	Tensão % nas linhas	% de carga nas âncoras
VERDADEIRO	11,27 %	1,2 graus	59,79%	94,26%

Fonte: Elaborado pela autora (2023).

No entanto, mesmo com a obtenção de uma solução que atende às três restrições técnicas estabelecidas, é importante destacar que o valor de offset de 11,27% ainda ultrapassa o limite máximo recomendado de 10%. Essa não conformidade novamente evidencia a necessidade de reavaliar a solução atualmente proposta, de modo a adequá-la integralmente aos parâmetros definidos para o sistema.

Essa segunda reavaliação configura-se como um passo essencial no aprimoramento contínuo da metodologia adotada, buscando assegurar que os resultados obtidos não apenas satisfaçam os critérios operacionais, mas também estejam plenamente alinhados às recomendações de projeto.

Apesar dessa inconformidade pontual, os resultados alcançados até o momento representam um avanço significativo na otimização do sistema de ancoragem. A análise detalhada, aliada à identificação de oportunidades de melhoria, demonstra uma trajetória positiva no desenvolvimento do projeto.


O próximo ciclo de aprimoramento será direcionado pela reavaliação crítica da solução atual, com foco em alcançar um grau mais elevado de desempenho e conformidade normativa.

### 4.1.3 Resultados da terceira etapa do processo de otimização

Após os ajustes realizados na segunda etapa, a terceira fase do processo de otimização foi conduzida com a incorporação de melhorias. Essa etapa representou um avanço importante na tentativa de encontrar configurações viáveis que respeitassem todas as restrições técnicas, ao mesmo tempo em que se aproximassem do valor de offset recomendado.

A Figura 50 apresenta a distribuição dos resultados referentes à porcentagem de offset a partir do neutro ao longo das iterações do processo de otimização. Cada ponto destacado no gráfico denota uma possível solução, proporcionando uma perspectiva gráfica do avanço contínuo observado durante o processo.

Figura 50 – Porcentagem de offset a partir do neutro em função das iterações.



Fonte: Elaborado pela autora (2023).

Na terceira etapa da análise, foi identificada uma solução ótima que representou um avanço significativo em relação às iterações anteriores. A configuração encontrada apresentou 9,92% de offset a partir do neutro, 1,68 graus de delta yaw neutro, 59,54% de tensão nas linhas e 93,69% de carga nas âncoras. Esses valores indicam que a solução não apenas atende a todas as restrições técnicas impostas, como também respeita a recomendação de manter o offset a

partir do neutro abaixo de 10%, critério essencial para a operação segura da plataforma. Os resultados consolidados dessa configuração ótima estão apresentados no Quadro 14.

Quadro 14 – Resultados da terceira análise.

TERCEIRA ANÁLISE				
VIÁVEL	Offset % a partir do neutro	Delta yaw neutro	Tensão % nas linhas	% de carga nas âncoras
VERDADEIRO	9,92 %	1,68 graus	59,54%	93,69%

Fonte: Elaborado pela autora (2023).

Dessa forma, a análise realizada nesta etapa atendeu integralmente a todas as restrições impostas, bem como à recomendação referente ao limite máximo permitido para a porcentagem de offset a partir do neutro. Nesse contexto, os resultados obtidos não apenas evidenciam a conformidade com os parâmetros técnicos e normativos, mas também consolidam a solução encontrada como uma solução ótima para o projeto de ancoragem proposto.

Contudo, é importante destacar que os processos de otimização, por sua própria natureza, frequentemente envolvem desafios complexos e não garantem, de forma imediata, a obtenção de uma solução única ou definitiva. Por esse motivo, são necessárias avaliações contínuas e ajustes progressivos, os quais exigem conhecimentos especializados e estudos aprofundados na área.

Além disso, ressalta-se que a duração e o grau de refinamento do processo estão diretamente relacionados à complexidade do modelo utilizado, evidenciando a necessidade constante de adaptação e aprimoramento das estratégias adotadas.

#### 4.2 RESULTADOS PARA O MODELO PREDITIVO

Para cada uma das quatro variáveis críticas do sistema de ancoragem, porcentagem de offset a partir do neutro, delta yaw neutro, porcentagem de tensão nas linhas e porcentagem de carga nas âncoras, foi desenvolvido um modelo preditivo independente utilizando o mesmo conjunto de variáveis de entrada.

Todos os modelos passaram por um fluxo unificado de pré-processamento e treinamento: inicialmente, as entradas foram normalizadas pelo MinMaxScaler; em

seguida, empregou-se o GridSearchCV com validação cruzada em cinco partições (5-Fold) para otimização dos hiperparâmetros; o treinamento foi realizado por até 350 épocas, com os callbacks EarlyStopping (patience=20) e ReduceLROnPlateau garantindo a paralisação automática em caso de estagnação e o refinamento da taxa de aprendizado; por fim, a taxa de aprendizado foi reduzida progressivamente de 0,0005 para 0,0001, de modo a permitir ajustes cada vez mais finos sem comprometer a convergência.

O principal objetivo foi avaliar a capacidade de generalização de cada modelo e sua acurácia na predição das respectivas variáveis, com base nos dados obtidos por simulação. A seguir, são apresentados os resultados individuais de cada modelo, com destaque para as métricas de desempenho ( $R^2$ , MSE e MAE) e a comparação gráfica entre os valores previstos e os valores reais, de modo a avaliar a precisão preditiva alcançada em cada caso.

#### **4.2.1 Resultados do modelo preditivo para offset a partir do neutro**

O desenvolvimento do modelo preditivo voltado à estimativa da variável porcentagem de offset a partir do neutro utilizou duas camadas ocultas compostas por 64 neurônios cada, com função de ativação ReLU, aplicação de dropout de 0,1 e regularização L2 com coeficiente de 0,0001. O treinamento foi realizado com taxa de aprendizado de 0,001, otimizador Adam e batch size de 128, empregando as estratégias de EarlyStopping (patience = 20) e ReduceLROnPlateau, com o objetivo de mitigar o sobreajuste e promover a estabilidade do treinamento.

No conjunto de teste, o modelo demonstrou desempenho altamente satisfatório. O coeficiente de determinação ( $R^2$ ) atingiu o valor de 0,95, evidenciando que 95% da variabilidade da variável de saída foi explicada pelas variáveis de entrada. As métricas de erro também indicaram elevada acurácia, com erro quadrático médio (Mean Squared Error – MSE) de 1,2% e erro absoluto médio (Mean Absolute Error – MAE) de 1,4%, valores considerados baixos para a natureza do problema.


A Figura 51 exibe um gráfico de dispersão entre os valores reais e os valores previstos para o conjunto de teste, incluindo uma linha de referência que representa a correspondência perfeita entre os dois conjuntos de dados. A densa concentração de pontos ao longo da diagonal indica uma forte correlação entre os

valores previstos e reais, com baixa dispersão, mesmo em diferentes faixas de offset.

Pequenos desvios pontuais foram observados, mas não comprometeram a robustez geral do modelo. Esses desvios são esperados, especialmente em faixas com menor densidade amostral.

Em síntese, o modelo preditivo desenvolvido para a variável offset % a partir do neutro demonstrou excelente desempenho, tanto em termos de aprendizado quanto de generalização. Sua capacidade de prever com precisão valores não vistos durante o treinamento reforça sua efetividade como ferramenta de apoio no processo de otimização de sistemas de ancoragem offshore, contribuindo para decisões mais ágeis e confiáveis em ambientes operacionais complexos.

Figura 51 – Comparação entre valores reais e previstos para o offset.



Fonte: Elaborado pela autora (2024).

A visualização apresentada na Figura 51 complementa as métricas numéricas, permitindo uma análise qualitativa da performance do modelo. A predominância de pontos alinhados à diagonal confirma a eficácia da rede em reproduzir o comportamento da variável de saída. Esse resultado não apenas valida a estrutura da rede e os hiperparâmetros adotados, como também indica que o modelo é adequado para aplicação no ambiente de otimização, substituindo com eficiência as simulações tradicionais.

#### **4.2.2 Resultados do modelo preditivo para o delta yaw neutro**


O modelo preditivo desenvolvido para a variável delta yaw neutro utilizou quatro camadas ocultas com 64 neurônios cada, função de ativação ReLU, dropout de 0,1 e regularização L2 com coeficiente de 0,0001. O treinamento foi realizado com taxa de aprendizado de 0,001, otimizador Adam e batch size de 128, contando com as estratégias de EarlyStopping (patience = 20) e ReduceLROnPlateau, a fim de evitar o sobreajuste e otimizar o processo de aprendizado.

Essa configuração apresentou desempenho robusto, com resultados consistentes tanto em acurácia quanto em capacidade de generalização. No conjunto de teste, o modelo alcançou um coeficiente de determinação ( $R^2$ ) de 0,92, evidenciando que aproximadamente 92% da variabilidade da variável de saída foi explicada pelas variáveis de entrada. As métricas de erro também demonstraram precisão: o erro quadrático médio (Mean Squared Error – MSE) foi de 2,2% e o erro absoluto médio (Mean Absolute Error – MAE) foi de 1,7%.

A Figura 52 apresenta um gráfico de dispersão entre os valores reais e os valores previstos pelo modelo, com uma linha de referência indicando o cenário ideal de predição perfeita. A distribuição dos pontos ao longo da diagonal demonstra boa aderência entre os valores previstos e observados, mesmo em faixas de maior variação da variável. Os pequenos desvios locais observados não comprometem a performance global, indicando que o modelo conseguiu capturar com fidelidade a tendência dos dados reais.

Em resumo, o modelo preditivo para delta yaw neutro demonstrou não apenas eficiência no aprendizado, mas também elevada capacidade de generalização, sendo uma ferramenta eficaz para suporte à otimização do sistema de ancoragem.

Figura 52 – Comparação entre valores reais e previstos para o delta yaw neutro.



Fonte: Elaborado pela autora (2024).

#### 4.2.3 Resultados do modelo preditivo para tensão nas linhas


Para a variável porcentagem de tensão nas linhas, adotou-se três camadas ocultas de 128 neurônios cada, função de ativação ReLU, dropout de 0,2 e regularização L2 com coeficiente igual a 0,0001. O modelo foi treinado com taxa de aprendizado de 0,001, otimizador Adam, batch size de 64, empregando EarlyStopping (patience=20) e ReduceLRonPlateau para prevenir overfitting.

No conjunto de teste, os resultados confirmaram a qualidade do modelo. O coeficiente de determinação ( $R^2$ ) foi de 0,89, o que indica que aproximadamente 89% da variabilidade nos valores de saída foi explicada pelas variáveis de entrada. As métricas de erro também se mantiveram em patamares baixos, com um erro quadrático médio (Mean Squared Error – MSE) de 2,3% e um erro absoluto médio (Mean Absolute Error – MAE) de 3,1%, reforçando a acurácia das previsões.

A Figura 53 apresenta um gráfico de dispersão que compara os valores reais e os valores previstos para o conjunto de teste, acompanhado de uma linha de referência diagonal, que representa o alinhamento ideal entre previsão e realidade. A proximidade dos pontos em relação a essa linha evidencia a capacidade do modelo em reproduzir os valores esperados com elevada fidelidade. Observa-se que a maioria das amostras está distribuída de forma concentrada ao longo da diagonal, o que indica baixa dispersão dos erros e alto grau de correlação entre os dados reais e os estimados.

Mesmo nas regiões com maior variação da variável-alvo, o modelo manteve um bom desempenho, capturando adequadamente o padrão geral do comportamento. Essa aderência aos dados reais reforça a robustez da arquitetura adotada e demonstra que o modelo é confiável para ser aplicado em contextos reais de otimização e análise de desempenho em sistemas de ancoragem.

Figura 53 – Comparação entre valores reais e previstos para a tensão.



Fonte: Elaborado pela autora (2024).

#### 4.2.4 Resultados do modelo preditivo para carga nas âncoras

O modelo preditivo construído para estimar a porcentagem de carga nas âncoras foi desenvolvido com quatro camadas ocultas compostas por 256 neurônios cada, utilizando a função de ativação ReLU, dropout de 0,1 e regularização L2 com coeficiente de 0,0001. O treinamento foi realizado com taxa de aprendizado de 0,001, otimizador Adam e batch size de 128, empregando as técnicas de EarlyStopping (patience = 20) e ReduceLROnPlateau para evitar sobreajuste.

No conjunto de teste, o modelo apresentou desempenho robusto. O coeficiente de determinação ( $R^2$ ) foi de 0,90, o que indica que 90% da variabilidade nos valores de saída foi explicada pelas variáveis de entrada. As métricas de erro também se mantiveram em patamares baixos, com erro quadrático médio (Mean Squared Error – MSE) de 2,4% e erro absoluto médio (Mean Absolute Error – MAE) de 3,3%, o que reforça a acurácia das previsões mesmo em um intervalo de valores mais amplo.


A Figura 54 apresenta um gráfico de dispersão entre os valores reais e os valores previstos para o conjunto de teste, incluindo uma linha de referência que representa a correspondência ideal entre os dados. A maioria dos pontos se encontra próxima à linha, evidenciando forte correlação e baixa dispersão dos erros. Ainda que algumas discrepâncias sejam perceptíveis em faixas superiores de carga, o modelo conseguiu acompanhar adequadamente as tendências gerais do comportamento da variável.

A concentração dos pontos próximos à linha de identidade no gráfico de dispersão destaca a capacidade do modelo em realizar previsões confiáveis, mesmo diante da elevada variação dos dados de entrada. Em especial, a leve dispersão observada em valores mais altos de carga não compromete a eficácia geral do modelo, considerando a complexidade do comportamento dinâmico das forças nas linhas de ancoragem.

Assim, o modelo preditivo desenvolvido para a variável carga nas âncoras não apenas demonstra elevado desempenho estatístico, como também se mostra adequado para ser incorporado ao processo de otimização automatizada, fornecendo estimativas com agilidade e precisão suficientes para apoiar decisões em projetos offshore complexos.

Esse resultado confirma a robustez e utilidade do modelo como ferramenta preditiva, sendo especialmente relevante para acelerar o processo de otimização do sistema de ancoragem sem comprometer a confiabilidade técnica das análises.

Figura 54 – Comparação entre valores reais e previstos para a carga.



Fonte: Elaborado pela autora (2024).

#### 4.3 RESULTADOS DO PROCESSO DE OTIMIZAÇÃO UTILIZANDO O MODELO PREDITIVO COM REDES NEURAS ARTIFICIAIS

Com o modelo preditivo devidamente treinado e validado para as quatro variáveis de saída (offset a partir do neutro, delta yaw neutro, tensão nas linhas e carga nas âncoras), tornou-se viável integrá-lo ao processo de otimização dos sistemas de ancoragem no software Synapse. Essa integração teve como principal acelerar a geração e a avaliação de soluções, substituindo o uso do programa Dynasim pelas estimativas fornecidas diretamente pelas redes neurais artificiais.

A incorporação do modelo preditivo permitiu reduzir significativamente o tempo computacional necessário para a avaliação de soluções, viabilizando uma exploração mais ampla e eficiente do espaço de busca. Além disso, o uso das RNAs possibilitou uma resposta às exigências de restrições técnicas, mantendo a precisão dos resultados por meio de validações regulares.

Durante o processo, foram conduzidas múltiplas etapas de refino, baseadas na comparação entre as previsões geradas pelo modelo e os valores obtidos por meio do Dynasim. Essa verificação cruzada foi essencial para assegurar a consistência dos resultados e orientar ajustes nas restrições, na arquitetura da rede e na seleção de dados utilizados no ajuste fino.

Cada nova rodada de otimização buscou aprimorar a aderência entre os valores estimados e os requisitos operacionais, demonstrando a eficácia do uso de redes neurais artificiais como ferramenta de suporte ao projeto de sistemas offshore.

#### **4.3.1 Primeira etapa – Avaliação inicial das soluções com o modelo preditivo**

Na primeira etapa do processo de otimização utilizando o modelo preditivo, foram geradas 100 soluções via amostragem Sobol, respeitando os limites iniciais das variáveis de entrada. Para isso, foi desenvolvido um novo modelo no software Synapse, onde o solver original baseado no programa Dynasim foi substituído por um script Python capaz de acessar diretamente os modelos preditivos treinados.

Essas soluções foram processadas automaticamente por meio do modelo preditivo, o que possibilitou uma avaliação rápida e eficiente dos resultados esperados para as quatro variáveis de saída. Em paralelo, reservou-se um conjunto de 20 % dos dados como hold-out para validar o ajuste final, garantindo que nenhum parâmetro fosse calibrado a partir dessas amostras. No entanto, ao submeter essas mesmas soluções ao programa Dynasim, observou-se que os valores simulados apresentaram grandes discrepâncias em relação às previsões, tanto para o offset quanto para as três restrições técnicas (delta yaw, tensão nas linhas e carga nas âncoras).

Embora algumas soluções tivessem apresentado previsões promissoras no ambiente do Synapse, os testes de validação revelaram erros significativos, demonstrando que o modelo ainda não estava devidamente ajustado para fornecer estimativas confiáveis em todo o espaço de busca. Isso demonstrou que o bom

desempenho observado nas métricas de teste convencionais não se traduzia, necessariamente, em acurácia prática quando aplicado a novas combinações de variáveis de entrada dentro do Synapse.

Durante a validação das 100 soluções geradas, foi realizado o cálculo do erro médio entre os valores previstos pelo modelo preditivo e os valores reais obtidos com o Dynasim. Esse indicador teve como objetivo quantificar, de maneira objetiva, a discrepância observada nesta etapa inicial. O resultado revelou um erro médio considerável de aproximadamente 12%, evidenciando a necessidade de ajustes adicionais.

Diante desse cenário, concluiu-se que, apesar do avanço proporcionado pela automação da análise via modelo preditivo, a sua aplicação direta ainda exigia refinamentos. Assim, definiu-se a realização de uma segunda etapa, voltada para o ajuste fino do modelo, com o objetivo de melhorar sua capacidade de generalização e garantir maior aderência aos resultados do simulador dinâmico.

#### **4.3.2 Segunda etapa – Ajuste fino do modelo preditivo e nova avaliação das soluções**

Após a constatação dos erros significativos na primeira etapa, foi realizada uma nova rodada de avaliação com o modelo preditivo ajustado por meio da técnica de ajuste fino. Para isso, aplicou-se a técnica de ponderação por amostras (`sample_weight`) durante o treinamento, atribuindo peso 10 às 100 novas amostras e peso 1 às soluções originais, de modo a concentrar o aprendizado nas regiões críticas do espaço de busca.

O procedimento utilizou o mesmo ambiente de otimização no software Synapse, onde foram geradas mais 100 soluções via amostragem Sobol, respeitando os limites originalmente definidos para as variáveis de entrada. Manteve-se 20% dessas soluções como hold-out para validação independente, não utilizados no ajuste fino. O modelo foi recompilado com taxa de aprendizado reduzida para 0,0005. Essas soluções foram processadas pelo modelo preditivo atualizado, e os resultados obtidos foram submetidos à validação no programa Dynasim, com o intuito de verificar a consistência entre as previsões e os dados simulados.

A comparação entre os valores previstos e os valores reais evidenciou uma melhora significativa em relação à etapa anterior. As quatro variáveis de saída apresentaram discrepâncias menores, sinalizando que o ajuste fino contribuiu diretamente para o aumento da acurácia do modelo, especialmente em regiões críticas do espaço de busca.

Apesar da evolução observada, nenhuma das soluções geradas nesta etapa conseguiu satisfazer simultaneamente as três restrições técnicas e a recomendação de offset inferior a 10%. Ainda assim, os erros médios globais foram substancialmente reduzidos, atingindo aproximadamente 5,1%, o que consolidou a importância da etapa de ajuste fino no aprimoramento da capacidade preditiva do modelo. Esses resultados reforçaram não apenas a eficácia do ajuste fino, mas também a necessidade de revisar o espaço de busca.

A constatação de que as limitações impostas às variáveis de entrada poderiam estar restringindo o alcance de soluções viáveis motivou a próxima etapa do processo, voltada à redefinição das restrições do modelo de otimização.

#### **4.3.3 Terceira etapa – Avaliação das soluções com restrições revisadas**

Na terceira etapa, com o objetivo de refinar o espaço de busca e aumentar a viabilidade das soluções geradas, foram revistas as restrições impostas às variáveis de entrada no programa Synapse. Essa reconfiguração considerou os limites máximos e mínimos efetivamente observados durante as simulações anteriores, assim como os requisitos operacionais do sistema de ancoragem, permitindo um melhor alinhamento entre o espaço de projeto e a realidade prática do problema.

Com essas modificações, foi gerado um novo conjunto de 100 soluções geradas via amostragem Sobol, mantendo 20% dos pontos reservados para validação independente, e respeitando integralmente os limites atualizados. As soluções foram processadas utilizando o modelo preditivo previamente ajustado, e os resultados foram novamente validados no programa Dynasim.

A aplicação das restrições revisadas teve um impacto positivo nos resultados, com redução dos erros médios para 1,7% e maior proporção de soluções viáveis em relação às etapas anteriores. As quatro saídas apresentaram melhor aderência entre os valores previstos e os valores simulados.

Apesar da melhora substancial, ainda não foi identificada uma solução que atendesse simultaneamente às três restrições técnicas e à recomendação de offset inferior a 10%. No entanto, os avanços observados nessa etapa reforçaram a efetividade da estratégia adotada, validando a robustez do modelo preditivo e estabelecendo uma base metodológica mais sólida para os refinamentos subsequentes.

#### **4.3.4 Quarta etapa – Novo ajuste com ampliação do conjunto de dados**

Dando continuidade ao processo de aprimoramento do modelo preditivo, a quarta etapa foi marcada pela realização de um novo ajuste fino, desta vez com a incorporação de um conjunto de dados ampliado e mais representativo. Para isso, foram utilizados 300 dados rotulados com os valores reais simulados no programa Dynasim, provenientes das etapas anteriores do processo de otimização.

O objetivo foi reforçar a capacidade do modelo de generalizar em regiões críticas do espaço de busca, priorizando amostras mais relevantes para a convergência do sistema. Como todos os dados estavam contidos no novo espaço de busca, foi possível aplicar pesos iguais para todas as amostras. O modelo preditivo previamente ajustado foi carregado, os escaladores (MinMaxScaler) recarregados e o modelo recompilado com taxa de aprendizado = 0,0001, utilizando os novos dados combinados com os anteriores.

Após o novo treinamento, o desempenho do modelo apresentou uma melhora consistente, evidenciada pela redução adicional dos erros médios para 0,8% e pela maior estabilidade nas previsões, mesmo em regiões mais sensíveis do espaço amostral. Uma nova rodada de soluções foi então gerada no ambiente Synapse e, em seguida, submetida ao programa Dynasim para validação.

Os resultados revelaram uma proximidade ainda maior entre os valores previstos e os valores reais simulados, indicando que o modelo estava se tornando cada vez mais confiável para a tarefa de substituição parcial do solver dinâmico. Apesar disso, ainda não foi identificada uma única solução que atendesse simultaneamente às três restrições técnicas e ao limite de offset recomendado.

No entanto, o número de soluções viáveis aumentou consideravelmente, evidenciando que o modelo preditivo estava convergindo de forma eficaz e

ganhando maior capacidade de generalização nas regiões críticas do domínio do problema.

Essa etapa consolidou a importância da incorporação progressiva de dados reais no ciclo de treinamento e validação, estabelecendo as bases para uma última rodada de ajuste fino, apresentada na etapa seguinte, com o intuito de finalmente identificar soluções plenamente compatíveis com todos os critérios estabelecidos.

#### **4.3.5 Quinta etapa – Ajuste final e identificação da solução ótima**

Na quinta e última etapa do processo de otimização com o modelo preditivo, foi conduzido um ajuste final, incorporando o conjunto mais robusto de dados utilizados até então. Foram considerados 400 dados rotulados com valores reais simulados: os 300 dados das etapas anteriores e mais 100 novos dados obtidos após a quarta rodada de geração de soluções.

O modelo previamente ajustado passou por um novo ciclo de treinamento, utilizando novamente a estratégia de ajuste fino, agora com esse conjunto ampliado. Esse processo de refino visou consolidar o aprendizado em regiões críticas do espaço de busca, aumentando a estabilidade e a capacidade de generalização do modelo preditivo.

As novas soluções geradas pelo modelo no ambiente Synapse foram então validadas no programa Dynasim, e pela primeira vez, uma solução foi capaz de atender simultaneamente às quatro condições impostas pelo estudo: limite máximo de offset, delta yaw neutro inferior a  $2^\circ$ , tensão nas linhas inferior a 60% e carga nas âncoras inferior a 100%.

Para comprovar a aderência entre os resultados obtidos pelo modelo preditivo baseado em redes neurais artificiais e os valores reais simulados no programa Synapse Offshore, foram elaborados gráficos comparativos no software Dynasim para as quatro variáveis de saída avaliadas: offset a partir do neutro, delta yaw neutro, tensão nas linhas e carga nas âncoras.

No caso da variável offset a partir do neutro, o valor estimado inicialmente pelo modelo preditivo para a posição crítica foi de 9,77%. Após aplicação do ajuste por distância euclidiana, que fornece uma estimativa mais precisa da posição real, esse valor foi corrigido para 9,87%. Para a mesma solução, o Synapse Offshore

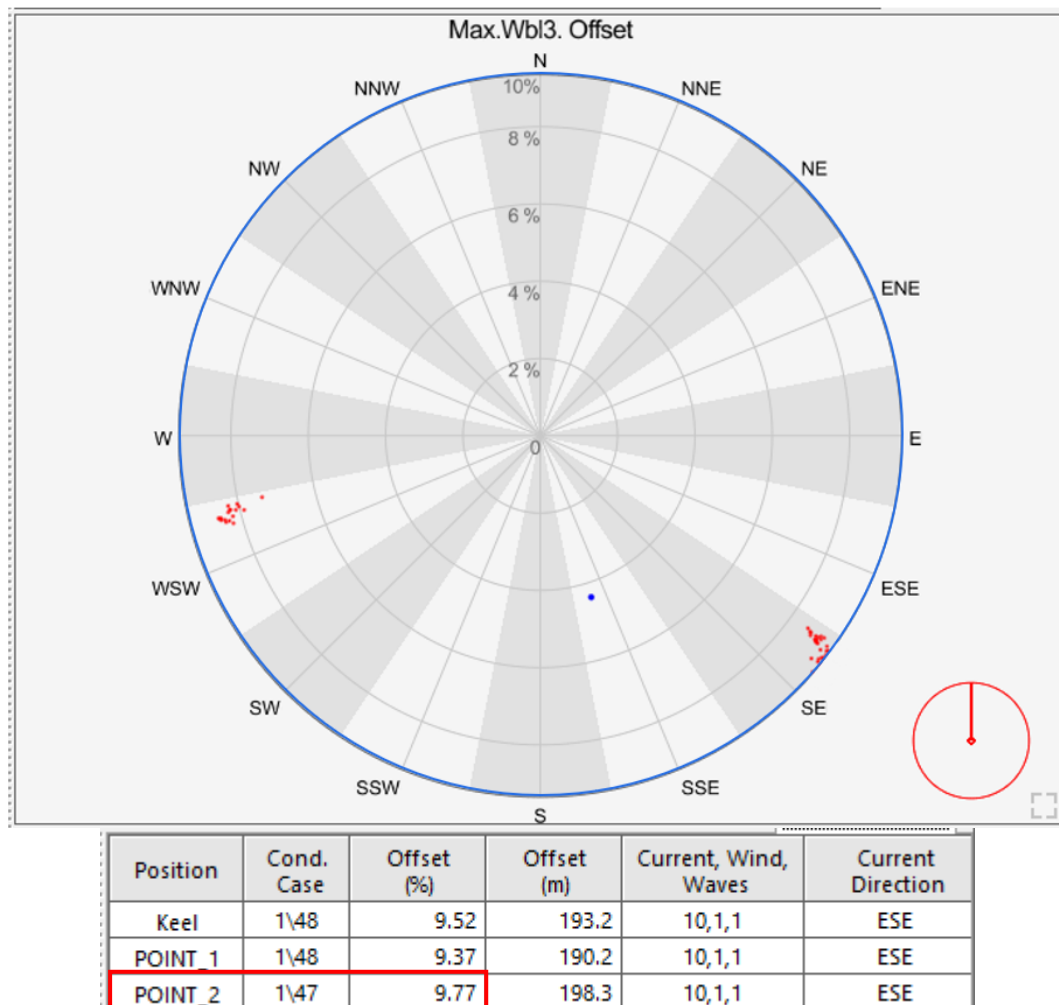
indicou inicialmente 9,82%, com ajuste final para 9,92% após o mesmo procedimento.

A Figura 55 apresenta o valor estimado pelo modelo preditivo (antes da correção), enquanto a Figura 56 mostra o valor correspondente obtido pelo Synapse Offshore. Ambas as representações, geradas no programa Dynasim, evidenciam a proximidade entre os valores previstos e reais, demonstrando a capacidade do modelo de representar com precisão o comportamento do sistema.

Essa etapa conclui o ciclo de aprimoramento do modelo preditivo, comprovando sua efetividade como ferramenta de apoio à otimização de sistemas de ancoragem offshore.

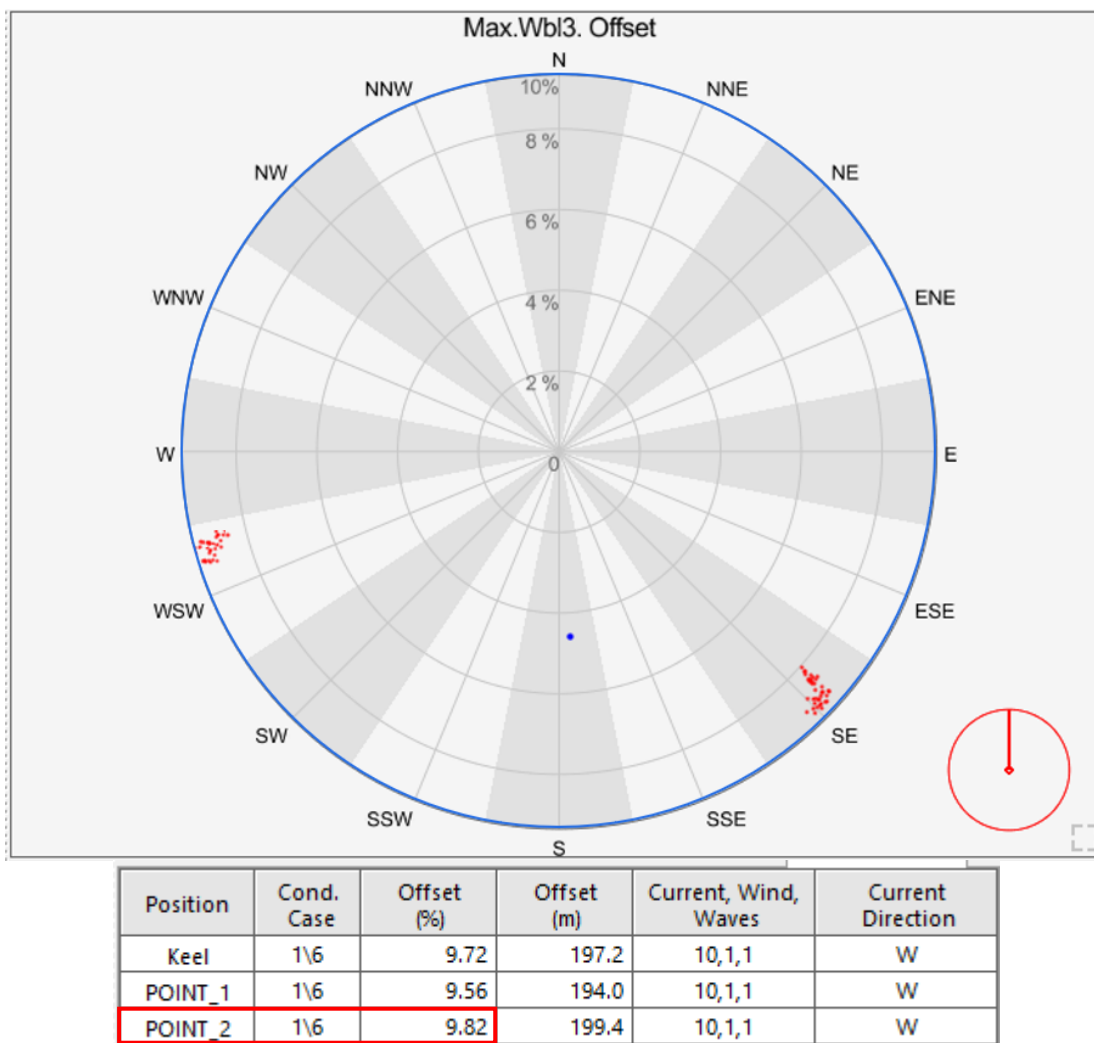
A identificação de uma solução viável dentro de todas as restrições marca o êxito da integração entre inteligência artificial e métodos computacionais de engenharia, validando a abordagem proposta nesta pesquisa.

Figura 55 – Offset % a partir do neutro estimado pelo modelo preditivo.



Fonte: Elaborado pela autora (2025).

Figura 56 – Offset % a partir do neutro obtido pelo Synapse Offshore.




Fonte: Elaborado pela autora (2025).

No caso específico da variável tensão nas linhas, o modelo preditivo indicou um valor de 59,34%. O gráfico correspondente, gerado no Dynasim, apresenta uma leitura de 98,9%, a qual deve ser multiplicada por 0,6 para converter ao valor utilizada no estudo, resultando assim no valor correto. Já para a mesma solução, o Synapse Offshore identificou uma tensão de 99,3%, o que, após a conversão, corresponde a 59,58%.


A Figura 57 apresenta o resultado obtido com o modelo preditivo para a tensão nas linhas, enquanto a Figura 58 exibe o valor correspondente encontrado pelo Synapse Offshore para a solução ótima. Ambos os gráficos foram gerados pelo Dynasim e permitem visualizar claramente a proximidade entre os dois valores, evidenciando a capacidade do modelo preditivo em estimar com boa precisão os resultados esperados.

Figura 57 – Tensão % nas linhas estimada pelo modelo preditivo.



Fonte: Elaborado pela autora (2025).

Figura 58 – Tensão % nas linhas obtida pelo Synapse Offshore.



Fonte: Elaborado pela autora (2025).

No caso da variável delta yaw neutro, o modelo preditivo estimou um valor de 1,60 graus para a solução considerada. Por outro lado, a simulação realizada no Synapse Offshore, com base nos dados processados no programa Dynasim, resultou em um valor de 1,68 graus, que foi posteriormente apresentado como 1,70 graus devido ao arredondamento automático realizado pelo sistema gráfico da ferramenta. A Figura 59 apresenta o valor estimado pelo modelo preditivo, enquanto a Figura 60 mostra o valor correspondente obtido por meio do Synapse Offshore. A proximidade entre os resultados reforça a confiabilidade do modelo preditivo na estimativa dessa variável, mesmo diante de pequenas variações introduzidas pela visualização gráfica da ferramenta.

Figura 59 – Delta yaw neutro (graus) estimado pelo modelo preditivo.

DX [m]	25.4
DY [m]	70.5
Offset [m]	74.9
DZ [m]	0.6
Roll [deg]	4.4
Pitch [deg]	0.1
Yaw [deg]	1.6

Fonte: Elaborado pela autora (2025).

Figura 60 – Delta yaw neutro (graus) obtido pelo Synapse Offshore.

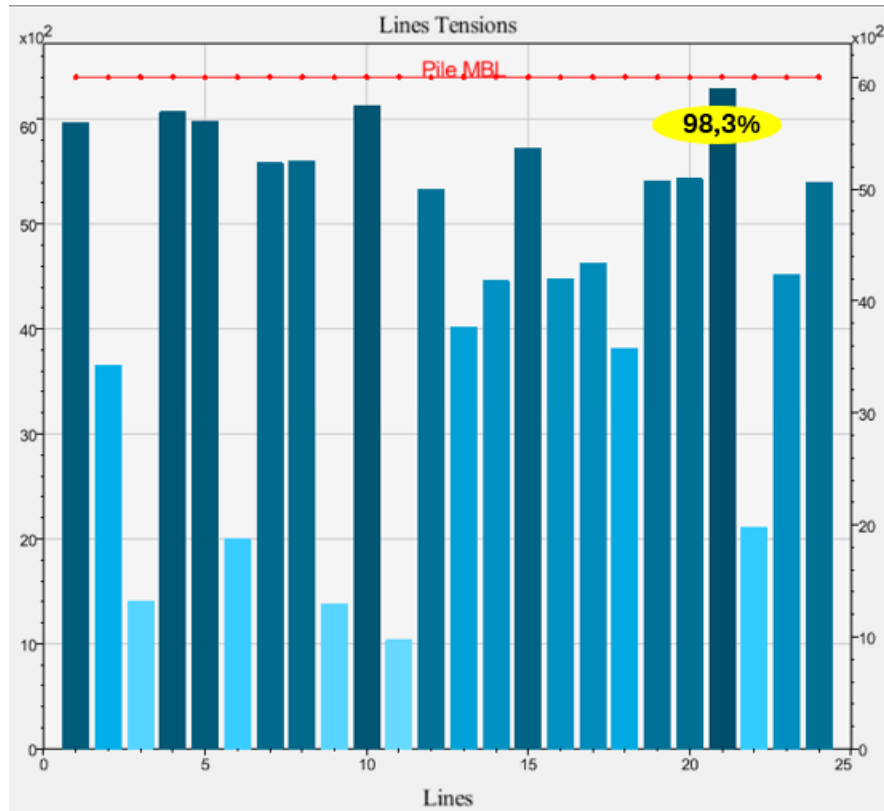
DX [m]	10.0
DY [m]	76.9
Offset [m]	77.6
DZ [m]	0.6
Roll [deg]	4.4
Pitch [deg]	0.1
Yaw [deg]	1.7

Fonte: Elaborado pela autora (2025).

No caso específico da variável porcentagem de carga nas âncoras, o modelo preditivo baseado em redes neurais estimou um valor de 98,3%. Para a mesma solução, o Synapse Offshore identificou um valor de 93,9%, ambos apresentados diretamente na escala adotada para o estudo, sem necessidade de conversão.


A Figura 61 apresenta o valor obtido pelo modelo preditivo para a carga nas âncoras, enquanto a Figura 62 mostra o resultado correspondente encontrado pelo Synapse Offshore. Os gráficos, gerados no programa Dynasim, permitem observar a proximidade entre os dois valores e reforçam a boa capacidade do modelo preditivo em representar adequadamente essa variável dentro do processo de otimização.

Figura 61 – % carga nas âncoras estimada pelo modelo preditivo.



Fonte: Elaborado pela autora (2025).

Figura 62 – % carga nas âncoras obtida pelo Synapse Offshore.



Fonte: Elaborado pela autora (2025).

Com o objetivo de avaliar a confiabilidade e a aplicabilidade da metodologia proposta, foi realizada uma comparação entre quatro conjuntos de resultados que representam diferentes abordagens de análise de um mesmo sistema de ancoragem. As soluções avaliadas foram obtidas por meios distintos, considerando:

- (i) a solução da primeira análise do projeto, antes da aplicação de qualquer ajuste, modificação ou otimização;
- (ii) a solução otimizada por meio do software Synapse Offshore;
- (iii) os valores previstos pelo modelo preditivo baseado em redes neurais artificiais (RNAs);
- (iv) a validação final no programa Dynasim, que simula o comportamento da unidade flutuante.

O Quadro 15 resume os valores obtidos por cada uma dessas abordagens para as quatro variáveis de interesse: offset a partir do neutro, delta yaw neutro, tensão nas linhas e carga nas âncoras.

Quadro 15 – Comparação final.

Resultados finais				
Origem da Solução	Offset (%) a partir do neutro	Delta yaw neutro (°)	Tensão (%) nas linhas	(%) de carga nas âncoras
Projeto Inicial	6,19	1,5	87,78	144,6
Synapse Offshore	9,92	1,68	59,58	93,9
Redes Neurais Artificiais	9,96	1,62	59,46	96,6
Validação no Dynasim	9,87	1,60	59,34	98,3

Fonte: Elaborado pela autora (2025).

Observa-se, inicialmente, que a solução do projeto inicial apresenta valores consideravelmente distintos, especialmente nas variáveis tensão nas linhas e carga nas âncoras, ambas ultrapassando os limites estabelecidos nas restrições de projeto. Isso se justifica pelo fato de que esses valores representam uma configuração inicial da plataforma, fornecida sem qualquer ajuste de engenharia. Ou

seja, trata-se de uma base inicial que não passou por nenhum processo de otimização, e, portanto, naturalmente não atende aos critérios técnicos definidos. Sua inclusão aqui serve como referência para destacar a evolução obtida com a aplicação das metodologias subsequentes.

Por outro lado, os três demais conjuntos de resultados, Synapse Offshore, Redes Neurais Artificiais e Dynasim, demonstram uma boa concordância entre si, especialmente nas variáveis de offset, delta yaw e tensão nas linhas, cujas diferenças ficaram abaixo de 0,3 unidades em todos os casos. Isso indica que o modelo preditivo foi capaz de capturar adequadamente os padrões complexos dessas variáveis e reproduzir o comportamento geral do sistema com elevada precisão.

A maior discrepância foi observada na variável carga nas âncoras, com uma diferença relativa de cerca de 4,4% entre os métodos. O modelo preditivo apresentou um leve aumento em relação aos valores obtidos pelo Synapse, o que pode estar relacionado à sensibilidade da variável a pequenas variações nas combinações de entrada ou à sua maior variabilidade nos dados de treinamento. Essa discrepância reforça a necessidade de contínuo aperfeiçoamento do modelo preditivo, por meio da incorporação de novos dados, reavaliação das variáveis de entrada mais relevantes ou mesmo ajustes na arquitetura da rede neural, especialmente para variáveis de maior complexidade não linear.

Contudo, é fundamental destacar que a comparação entre os quatro conjuntos de resultados exige uma análise criteriosa e deve ser feita com cautela. Apesar de todas as abordagens considerarem as mesmas variáveis de saída, os contextos, premissas e objetivos de cada uma delas são substancialmente diferentes. O projeto inicial não passou por qualquer otimização ou processo corretivo. Já a solução obtida no Synapse Offshore é fruto de um processo robusto de otimização conduzido por algoritmos genéticos, que explora diversas combinações de entrada para atender simultaneamente a diferentes critérios técnicos. O modelo preditivo com redes neurais artificiais, por sua vez, baseia-se em padrões aprendidos a partir de soluções anteriores, gerando estimativas diretas sem necessidade de simulações adicionais. Por fim, o Dynasim foi utilizado para validar os resultados obtidos pelo modelo preditivo.

Dessa forma, embora as variáveis de interesse sejam numericamente comparáveis, é incorreto assumir que essas quatro abordagens estejam lidando com

o mesmo projeto ou conjunto de premissas. São soluções derivadas de diferentes processos, com cenários de entrada distintos, e, portanto, representam projetos diferentes.

O valor de compará-los reside não na exatidão dos números em si, mas na convergência dos comportamentos observados. O fato de que as soluções otimizadas e preditas apresentaram valores muito próximos, mesmo sendo geradas por métodos com naturezas tão distintas, evidencia a robustez da metodologia proposta. A aproximação entre os resultados indica que a RNA foi capaz de reproduzir tendências confiáveis de projeto, o que valida sua aplicação como ferramenta de suporte à tomada de decisão no desenvolvimento de sistemas de ancoragem offshore.

Além disso, os resultados obtidos mostram que o modelo preditivo tem grande potencial para ser expandido. Embora este trabalho tenha focado em quatro variáveis principais, a flexibilidade das redes neurais artificiais permite adaptar o modelo para incluir outros objetivos de análise, como peso sistema, abertura do pattern, tração neutra nos guinchos, offset neutro, região de offset permitida e dentre outros. O modelo pode ser continuamente reconfigurado para se ajustar a diferentes requisitos operacionais, tipos de unidades offshore e contextos ambientais, tornando-se uma ferramenta versátil para múltiplos cenários na engenharia naval.

Outro benefício notável foi a significativa redução de tempo computacional, estimada em aproximadamente 30%, decorrente da substituição de simulações iterativas por previsões com uso da rede neural. Apesar da etapa de validação no Dynasim ainda demandar inserção manual das variáveis de entrada, o uso das RNAs representa um avanço rumo à automação completa do processo de projeto.

Em síntese, os resultados obtidos demonstram não apenas a viabilidade técnica da abordagem baseada em redes neurais, mas também sua eficiência, escalabilidade e aderência prática às exigências do projeto de sistemas de ancoragem offshore. Mesmo com margens para melhorias, especialmente na variável de carga nas âncoras, a metodologia se mostra promissora para projetos futuros que demandem agilidade, flexibilidade e precisão.

## 5 CONCLUSÃO

A realização deste trabalho permitiu a construção de uma abordagem integrada e iterativa voltada à otimização de sistemas de ancoragem, com o uso de técnicas tradicionais combinadas com as ferramentas baseadas em inteligência artificial. O estudo foi desenvolvido em três etapas principais, cada uma delas com objetivos específicos e contribuições complementares para a análise do comportamento e desempenho do sistema de ancoragem de plataformas offshore.

Na primeira etapa, conduziu-se o processo de otimização tradicional utilizando o programa Synapse Offshore com o solver baseado no simulador Dynasim. Nessa fase, foram geradas soluções visando minimizar a porcentagem de offset a partir do neutro, respeitando simultaneamente três restrições críticas: o limite máximo para o delta yaw neutro, a porcentagem de tensão nas linhas e a carga nas âncoras. Embora essa abordagem tenha identificado soluções tecnicamente viáveis, o tempo demandado para simulação e verificação era elevado, ultrapassando a marca das 3 semanas de processamento.

Na segunda etapa, buscou-se superar essas limitações por meio do desenvolvimento de um modelo preditivo baseado em redes neurais artificiais. Essa rede foi treinada com um conjunto de dados reais simulados no Dynasim, e submetida a uma rigorosa validação por meio da divisão dos dados em conjuntos de treinamento e teste, além do ajuste de hiperparâmetros com GridSearchCV, regularização L2, uso de dropout, EarlyStopping e redução adaptativa da taxa de aprendizado. Ao final, foram obtidas quatro redes preditivas específicas, uma para cada variável de saída de interesse, com altos níveis de desempenho, obtendo coeficientes de determinação ( $R^2$ ) relativamente altos e erros médios absolutos (MAE) extremamente baixos, o que indicava uma excelente capacidade de generalização dos modelos.

A terceira e última etapa consistiu na integração desses modelos preditivos ao processo de otimização no Synapse. Para isso, o solver do Dynasim foi substituído por scripts em Python capazes de acessar diretamente os modelos treinados, permitindo assim a geração e avaliação instantânea de centenas de soluções com tempo de resposta significativamente reduzido. O modelo preditivo passou a atuar como um acelerador no processo de otimização, permitindo explorar o espaço de busca com muito mais agilidade, identificando rapidamente regiões

promissoras. Esse processo foi aperfeiçoado por meio de múltiplas rodadas de refino, que incluíram a aplicação de ajuste fino com novos dados gerados, e a revisão das restrições e limites das variáveis de entrada.

Ao final do processo iterativo, foi possível encontrar uma solução viável que atendia simultaneamente às quatro condições impostas: offset inferior a 10%, delta yaw neutro inferior a 2 graus, tensão nas linhas abaixo de 60% e carga nas âncoras inferior a 100%. Os resultados preditivos para essa solução foram comparados aos valores simulados no Dynasim, e os erros encontrados foram mínimos, validando a confiabilidade dos modelos utilizados. A integração entre otimização e inteligência artificial mostrou-se eficaz, reduzindo consideravelmente o tempo total de análise em 30%, e abrindo caminho para aplicações futuras mais robustas.

A comparação entre os valores previstos e os resultados reais simulados no Dynasim validou a precisão dos modelos desenvolvidos, reforçando a confiabilidade da metodologia proposta. O uso das redes neurais mostrou-se eficiente não apenas como ferramenta de previsão, mas como um componente estratégico dentro do processo de tomada de decisão em projetos de engenharia offshore.

## 5.1 TRABALHOS FUTUROS

Como trabalho futuro, recomenda-se o aprimoramento contínuo dos modelos preditivos, com a ampliação do conjunto de dados utilizados no treinamento, incluindo simulações em diferentes cenários operacionais e com condições ambientais variáveis. Além disso, pode-se investigar o uso de outras arquiteturas de rede, para conduzir a otimização diretamente. Outro avanço promissor seria o desenvolvimento de uma interface que integre o Synapse Offshore diretamente aos modelos de IA poderá viabilizar um fluxo contínuo e em tempo real de geração, avaliação e seleção de soluções.

Em suma, este trabalho demonstrou que é possível otimizar sistemas complexos como o de ancoragem offshore com o suporte de redes neurais artificiais, desde que o processo seja conduzido com atenção à qualidade dos dados, às métricas de avaliação e à validação cruzada. Os resultados obtidos comprovam que a união entre engenharia tradicional para o projeto de sistemas de ancoragem e inteligência artificial pode oferecer ganhos substanciais em eficiência e precisão, consolidando-se como uma ferramenta promissora para a engenharia do futuro.

## REFERÊNCIAS

AGGARWAL, Charu C.; REDDY, Chandan K. **Data clustering: algorithms and applications**. Boca Raton: CRC Press, 2014.

ALBRECHT, C. H. **Algoritmos evolutivos aplicados à síntese e otimização de sistemas de ancoragem**. 2005. Tese (Doutorado em Ciências em Engenharia Oceânica) – Universidade Federal do Rio de Janeiro/ COPPE, Rio de Janeiro, 2005.

AMARAL, G. A. **Avaliação Analítica da Rigidez do Sistema de Amarração**. 2020. 153p. Dissertação (Mestrado em Ciências) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2020.

AMARAL, C. S.; COSTA, A. M. **Verificação dos fatores de segurança das estacas torpedo para o navio avaré no campo de coral**. Relatório parcial do projeto -601129. CENPES/PDP/MC, Rio de Janeiro, 2004.

AMORIM, T. O. **Plataforma offshore: uma breve análise a construção ao descomissionamento**. 2010. Trabalho de Conclusão de Curso (Graduação em Tecnólogo em Construção Naval) – Centro Universitário Estadual da Zona Oeste, Fundação Centro Universitário da Zona Oeste, Rio de Janeiro, 2010.

ANDRADE, H. M. P; MARTINS, M. A. L; LAGES, E. N. **Análise estática de linhas de ancoragem utilizando redes neurais artificiais**. 2015. Revista de Engenharia e Tecnologia. V.7, n. 3, ago./2015.

ARORA, J. S. **Introduction to Optimum Design**. 4. ed. Amsterdam: Elsevier, 2011.

AYRES, H. M; QUEIROZ, L. M. O; SANTOS, L. C. B; SILVA, R. C. **Algoritmo evolutivo para problemas de otimização multiobjetivo com incertezas**. 2007. XXXIX SBPO – A pesquisa operacional e o desenvolvimento sustentável, Fortaleza, Ceará, 2007.

AUSSOURD, P. N. C. **Aplicação de algoritmos genéticos em otimização de horários**. 2015. Trabalho de Conclusão de Curso (Ciência da Computação) – Universidade Católica de Pernambuco, Recife, 2015.

AZMIN, R.; STOBART, R. J. **A Sobol-Sequence–Based Design of Experiments for Efficient Exploration of High-Dimensional Design Spaces**. *Structural and Multidisciplinary Optimization*, v. 52, n. 3, p. 461–476, 2015.

BARBOZA, D. C. **Análise de esforços em linhas de sistemas de ancoragem de estruturas flutuantes**. 2022. Trabalho de Conclusão de Curso (Engenharia Mecânica) – Universidade Federal Fluminense, Engenharia Mecânica, Niterói, 2022.

BASTOS, P. S. **Ancoragem e emenda de armaduras**. 2018. Departamento de Engenharia Civil e Ambiental – Universidade Estadual Paulista, São Paulo, 2018.

BASTOS, H. K. O. **Otimização multiobjetivo para seleção simultânea de variáveis e objetos em cromossomo duplo de representação inteira para calibração multivariada**. 2017. Dissertação (Mestre em Ciências da Computação) – Instituto de Informática, Universidade Federal de Goiás, Goiânia, 2017.

BAZARAA, M. S.; SHERALI, H. D.; SHETTY, C. M. **Nonlinear Programming: Theory and Algorithms**. 3. ed. Hoboken: John Wiley & Sons, 2006.

BARBER, D. **Bayesian Reasoning and Machine Learning**. Cambridge: Cambridge University Press, 2017.

BERGSTRA, J., & BENGIO, Y. **Random Search for Hyper-Parameter Optimization**. (2012). *Journal of Machine Learning Research*.

BICO, V. M. P. **Amarração de plataformas offshore flutuantes com cabos de poliéster**. 2013. Dissertação de Mestrado. Dissertação de Mestrado (Mestrado em Engenharia Civil) – Área Departamental de Engenharia Civil, Instituto Superior de Lisboa, Lisboa, 2013.

BLANCO, J. P. I. **Aplicação da metodologia semi-acoplada para o projeto de um sistema de ancoragem em uma plataforma semissubmersível**. 2013. 78 f. Trabalho de Graduação (Engenharia Naval e Oceânica) – Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013.

BLUM, C; ROLI, A. **Metaheuristics in combinatorial optimization: Overview and conceptual comparison**. ACM Computing Surveys, v. 35, n. 3, p. 268–308, 2003.

CABRAL, M. V. S. **Otimização de estruturas treliçadas utilizando algoritmo genético**. 2005. Trabalho de Conclusão de Curso (Engenharia Civil) – Universidade Federal de Pernambuco (UFPE), Engenharia Civil, Caruaru, 2016.

CARBONO, A. J. J. **Otimização da Disposição de Linhas de Ancoragem Utilizando Algoritmos Genéticos**. 2005. Dissertação (Mestrado em Engenharia Civil) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005.

CATARINA, A. S. **Algoritmos evolutivos aplicados ao processo de análise de dados geográficos**. São José dos Campos, 2005.

CARDOSO, A. C. **Otimização de Ancoragem para Sondas de Perfuração e Intervenção**. 2014. Projeto de Graduação (Engenharia Naval e Oceânica) - Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2014.

CEOLATO, T. **Estudo do comportamento estrutural de elos de amarras de ancoragem**. 2019. Trabalho de Conclusão de Curso (Engenharia de Minas e de Petróleo) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2019.

CHAPELLE, O.; SCHOLKOPF, B.; ZIEN, A. **Semi-Supervised Learning**. Cambridge: MIT Press, 2010.

CHAVES, H. M. **Modelo Reduzido de Linha de Ancoragem Offshore: Construção de um Sistema de Ensaio para Avaliar Atenuação de Cargas**

**Estáticas**. 2020. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal do Rio Grande do Sul, Porto Alegre. 2020.

COSTA JÚNIOR, J. F.; Lima, U. F.; Leme, M. D.; Moraes, L. S.; Costa, J. B.; Barros, D. M.; Sousa, M. A. M. A.; Oliveira, L. C. F. de. **A inteligência artificial como ferramenta de apoio no ensino superior**. Revista Brasileira de Ensino e Aprendizagem, v. 6, p. 246-269, 2023. ISSN 2764-1368.

CRUZ, B. C. **Análise de métodos de otimização multiobjetivos aplicados a processos químicos**. 2022. Dissertação (Mestrado em Engenharia Química) – Escola de Engenharia, Universidade Federal Fluminense, Niterói, 2022.

DAER, T. M. **Otimização evolutiva de uma rede neural aplicada no sistema de ancoragem de plataformas flutuantes**. 2017. Trabalho de Conclusão de Curso (Graduação em Engenharia de Petróleo) – Escola de Engenharia Departamento de Engenharia Química e de Petróleo, Universidade Federal Fluminense, Niterói, 2017.

DEB, K. **Multi-objective optimization using evolutionary algorithms**. The International Journal of Computational Intelligence Research, v. 1, n. 6, p. 489–513, 2004.

DORIGO, M; STOUTZLE, T. **Ant Colony Optimization**. Cambridge: MIT Press, 2004.

EBERHART, R. C.; KENNEDY, J. **A new optimizer using particle swarm theory**. In: Proceedings of the Sixth International Symposium on Micro Machine and Human Science (MHS), Nagoya, Japan, 1995. p. 39–43.

FELISBINO, R. **Inteligência artificial e redes neurais: conceitos e aplicações**. 2012. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Instituto Municipal de Ensino Superior de Assis, Assis, São Paulo, 2012.

FERREIRA, F. M. G. **Otimização de sistema de ancoragem equivalente em profundidade truncada**. 2016. Tese (Doutorado em Engenharia Civil) Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Civil, 2016.

FERREIRA, J. A. B. **Redes neurais artificiais aplicadas em aprendizagem de trajetória em robótica móvel**. 2020. Dissertação (Mestrado em Sistemas Mecatrônicos) – Universidade de Brasília, Brasília, 2020.

FILITTO, D. **Algoritmos genéticos: uma visão explanatória**. 2008. Revista Multidisciplinar da UNIESP. Saber Acadêmico. 2008.

FURTADO, M. I. V. **Redes neurais artificiais: uma abordagem para sala de aula**. 2019. Ponta Grossa (PR): Atena Editora, 2019.

GARCIA, A.C. P. **Estimativa de tensão em linhas de ancoragem usando redes neurais**. 2023. Trabalho de Conclusão de Curso (Graduação em Engenharia) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2023.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems**. Sebastopol: O'Reilly Media, 2019.

GHALLAB, M.; NAU, D.; TRAVERSO, P. **Automated Planning: Theory and Practice**. 2. ed. Waltham: Morgan Kaufmann, 2016.

GIMENES, V. H. S. **Minimização de problemas de otimização multiobjetivo com incertezas paramétricas utilizando as metodologias de min-max deviation e estimativa do pior caso de incertezas**. 2020. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte, 2020.

GLOT, X.; BORDES, A.; BENGIO, Y. **Deep sparse rectifier neural networks**. In: Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, Fort Lauderdale, FL, USA, 2011. p. 315–323.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Reading: Addison-Wesley, 1989.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

GUO, B.; SONG, S.; GHALAMBOR, A.; LIN, T. R. Chapter 7 - **Pipeline Riser Design, Offshore Pipelines (Second Edition)**, Gulf Professional Publishing. 2014, Pages 79-102.

GUPTA, P. et al. **A survey on deep learning architectures and applications**. Journal of Artificial Intelligence Research, v. 70, p. 497–569, 2021.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2001. Porto Alegre: Bookman, 2001.

HERREIRA, J. I.; ATTUX, R. R. F.; COELHO, G. P. **Otimização evolutiva multiobjetivo: implementação do algoritmo NSGA-II**. 2021. XXIX Congresso de Iniciação Científica UNICAMP, 2021.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. Ann Arbor: University of Michigan Press, 1975.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. 2. ed. Melbourne: OTexts, 2018.

IANAGUI, A. **Robust system design for consensus control in dynamically positioned vessel fleet**. 2019. Dissertação (Mestrado em Engenharia Mecatrônica e de Sistemas Mecânicos) - Escola Politécnica da Universidade de São Paulo, São Paulo, 2019.

IOFFE, S.; SZEGEDY, C. **Batch normalization: accelerating deep network training by reducing internal covariate shift**. In: International Conference on Machine Learning, Lille, France, 2015. p. 448–456.

JACOVAZZO, B. M. **Comparação entre sistemas de ancoragem “Taut-leg” e convencional para unidades flutuantes ancoradas na exploração de petróleo offshore**. 2006. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

JUNIOR, M. T. **Desenvolvimento de uma ferramenta para dimensionamento de linhas de ancoragem em catenária para estruturas flutuantes**. 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia Naval) – Centro Tecnológico de Joinville, Universidade Federal de Santa Catarina, Joinville, 2019.

KHAN, S. A. et al. **A comprehensive survey of metaheuristic algorithms for optimization**. Swarm and Evolutionary Computation, v. 57, p. 100771, 2020.

KENNEDY, J; EBERHART, R. **Particle swarm optimization**. In: Proceedings of IEEE International Conference on Neural Networks, Perth, Australia, 1995. p. 1942–1948.

KROGH, A.; HERTZ, J. **A simple weight decay can improve generalization**. In: Advances in Neural Information Processing Systems, Denver, CO, USA, 1992. v. 4, p. 950–957.

KRUGERUD, C. **Design and Automated Optimization of Mooring Systems for Shallow Water and Harsh Environments**. 2016. Norwegian University of Science and Technology, Department of Marine Technology, 2016.

KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. New York: Springer, 2013.

KUN X., KJELL L., YANLIN S., MIN Z., ZHEN G., TORGEIR M., **Design and comparative analysis of alternative mooring systems for floating wind turbines in shallow water with emphasis on ultimate limit state design**. Ocean Engineering, Volume 219, 2021.

LEAL, G. S. **Avaliação de metodologia de projeto de sistemas de ancoragem de plataformas flutuantes em relação à fadiga**. 2016. Dissertação (Mestrado em Engenharia Oceânica) – Programa de Pós-graduação em Engenharia Oceânica, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2016.

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep Learning**. Nature, v. 521, n. 7553, p. 436–444, 2015.

LINCZUK, V. C. C; BASTOS, L. E. G. **Otimização multiobjetivo orientada ao desempenho térmico para o projeto de edificações de baixo consumo de energia na região sul do Brasil**. Ambiente Construído, Porto Alegre, v. 20, n. 4, p. 509-529, out./dez. 2020. ISSN 1678-8621 Associação Nacional de Tecnologia do Ambiente Construído.

MARLER, R. T.; ARORA, J. S. **Survey of multi-objective optimization methods for engineering**. Structural and Multidisciplinary Optimization, v. 26, n. 6, p. 369–395, 2004.

MARSON, G. A. **Análise comparativa dos algoritmos genéticos many-objective em problemas de otimização discreta**. 2017. Trabalho de Conclusão de Curso (Ciência da Computação) – Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais, 2017.

MARTINS, M. A. L. **Otimização da configuração de risers verticais complacentes**. 2011. Dissertação (Mestre em Engenharia Civil) – Universidade Federal de Alagoas, Maceió, 2011.

MARTZIKOS, A.; PANAGIOTAKOPOULOS, E.; ZERVOS, N. **A neural network-based model for predicting dynamic responses of offshore platforms**

**by integrating hydrodynamic and environmental data.** Ocean Engineering, v. 256, p. 111234, 2024.

MEDEIROS, I. E. A. **Aplicação de redes neurais artificiais para a previsão de demanda em subestações de distribuição considerando a influência da temperatura.** 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal da Paraíba, João Pessoa, 2019.

MELO, C. M. A. R. **Avaliação de desempenho e desenvolvimento de metodologias para estudos de ancoragem de estruturas flutuantes com estacas de sucção.** 2010. Dissertação (Mestre em Engenharia Civil) – Centro de Ciência e Tecnologia, da Universidade Estadual do Norte Fluminense, Campos dos Goytacazes, 2010.

MENDES, A. P. A.; TEIXEIRA, C. A. N.; ROCIO, M. A. R. Petróleo e gás. In: PUGA, F. P.; CASTRO, L. B. (org.). **Visão 2035: Brasil, país desenvolvido: agendas setoriais para alcance da meta.** Rio de Janeiro: BNDES, 2018. p. 53-88.

MINUSSI, C. R.; LOTUFO, A. D. P. **Redes neurais – Introdução e principais conceitos.** 2008. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual Paulista, Ilha Solteira, São Paulo, 2008.

MITCHELL, T. M. **Machine Learning.** 1. ed. New York: McGraw-Hill Education, 2019.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of Machine Learning.** 2. ed. Cambridge: MIT Press, 2018.

MUNIZ, T. J. C. **Auxílio multicritério à decisão aplicado na destinação de sistemas de produção de óleo e gás offshore em descomissionamento.** 2020. Dissertação (Mestrado em Engenharia de Produção e Sistemas Computacionais) – Instituto de Ciência e Tecnologia, Universidade Federal Fluminense, Rio das Ostras, 2020.

NASCIMENTO, W. W. d. S. **A inteligência artificial como ferramenta de apoio aos gerentes de projetos: um estudo de caso sobre o uso de chats para a identificação de riscos em projetos.** 2023. Trabalho de Conclusão de Curso (Graduação em Sistemas de Informação) - Centro de Informática, Universidade Federal de Pernambuco, Recife, 2023.

NAZÁRIO. C. S. **Modelagem de Sistemas de Ancoragem Utilizando Catenária Inelástica.** 2011. Trabalho de Conclusão de Curso - Curso de Engenharia Naval, Universidade Federal de Santa Catarina, UFSC, Joinville. 2015.

NEVES, C. **Seleção de um conceito de plataforma offshore para atuação na Baía de Santos, baseada na análise do movimento heave.** 2015. Trabalho de Conclusão de Curso (Graduação em Engenharia Naval) – Centro Tecnológico de Joinville, Universidade Federal de Santa Catarina, Joinville, 2015.

NISHIMOTO, K.; FUCATU, C. H.; MASETTI, I. Q. **Dynasim—A time domain simulator of anchored FPSO.** Journal of Offshore Mechanics and Arctic Engineering, American Society of Mechanical Engineers, v. 124, n. 4, p. 203–211, 2002.

NIKKHAH, M. et al. **Application of artificial neural networks combined with prospective methods to assess the structural integrity of FPSO mooring systems.** Journal of Marine Structures, v. 45, p. 123–137, 2021.

NOCEDAL, J; WRIGHT, S. J. **Numerical Optimization.** 2. ed. New York: Springer, 2006.

PAYENDA, K.; RAJ, S.; GUPTA, P. **A recurrent neural network architecture to estimate mooring line tensions in floating units.** Computational Mechanics, v. 63, n. 4, p. 899–912, 2024.

PETRÓLEO BRASILEIRO S. A. **Exploração e Produção.** 2025. Disponível em: <https://petrobras.com.br/quem-somos/exploracao-e-producao>. Acesso em: 20 abr. 2025.

PINA, A. A. **Metodologias de análise, síntese e otimização de sistemas para produção de petróleo offshore através de metamodelos e enxame de partículas**. Tese (Doutorado em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

PINTO, M. A. P. **Otimização de um plet baseada em análise estrutural pelo método de elementos finitos**. 2023. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) – Universidade Federal Fluminense, Niterói, Rio de Janeiro, 2023.

POOLE, D.; MACKWORTH, A.; GOEBEL, R. **Computational Intelligence: A Logical Approach**. 2. ed. Oxford: Oxford University Press, 2017.

RAMPAZZO, F. P. **Estudo de viabilidade do sistema de ancoragem de uma unidade flutuante de produção e armazenamento “FPSO” acoplada a um sistema de completação seca “TLWP”**. 2011. Trabalho de Mestrado (Mestre em Engenharia) – Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia Naval e Oceânica, São Paulo, 2011.

RAO, R. V.; PANAJI, S.; SATISH, K. **An improved particle swarm optimization algorithm for solving unconstrained optimization problems**. *Engineering Optimization*, v. 39, n. 2, p. 157–175, 2007.

RICETO, A; SILVA, RONALDO da. **O papel da Petrobras na economia brasileira (2003/2018): Ascensão e queda**. *GEOgraphia*, vol: 23, n.50, 2021.

RIVAI, M. A. B. **Analysis of mooring system design on floating platform of ocean current power plant using CFD (Computational Fluid Dynamics) method**. 2016. Bachelor Thesis– Marine Engineering Department, Faculty of Marine Technology, Institut Teknologi Sepuluh Nopember, Surabaya, 2016.

RODRIGUES, V. C. **Análise de fadiga de “risers” submetidos a vibrações induzidas por desprendimento de vórtices (VIV)**. 2011. Trabalho de

Conclusão de Curso (Engenharia Civil) – Escola Politécnica da Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

ROLÍ, A; STOUTZLE, T; BLUM, C. **Design and Analysis of Benchmark Problems for Combinatorial Optimization Metaheuristics**. Evolutionary Computation, v. 11, n. 4, p. 375–399, 2003.

RUSSELL, S. J., & Norvig, P. (2021). **Artificial intelligence: A modern approach** (4th ed.). Pearson.

SALGADO, R. **The Engineering of foundations**. 2008. McGraw-Hill Science/ Engineering/ Math, 1 edition, 896p. 2008.

SANTOS, F. K. M. **Redes neurais artificiais e suas aplicabilidades: modelagem do valor da temperatura máxima na cidade de Castanhal**. 2018. Trabalho de Conclusão de Curso (Graduação em Matemática) – Universidade Federal do Pará, Castanhal, 2018.

SAMPA, N.C. **Atenuação de cargas dinâmicas em linhas de ancoragem de plataformas offshore**. 2015. Dissertação (Mestre em Engenharia Civil) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015.

SILVA, F. S. **Sistemas de ancoragem de unidades flutuantes**. 2011. Trabalho de Conclusão de Curso (Graduação em Tecnologia em Construção Naval) – Centro Universitário Estadual da Zona Oeste, Secretaria de Estado de Ciência e Tecnologia, Rio de Janeiro, 2011.

SILVA, H. A. **Algoritmo de otimização multinível. Aplicado a problemas de planejamento de redes**. 2012. Tese (Doutor em Informática) – Informática da Pontifícia, Universidade Católica do Paraná, Curitiba, 2012.

SILVA, I. N; SPATTI, D; e FLAUZINO, R. (2010). **Redes neurais artificiais para engenharia e ciências aplicadas: curso prático**, Artliber Editora Ltda, São Paulo, SP, Brasil. ISBN978-85-88098-53-4.

SILVA, L. **Análise modal e controle de plataformas offshore sujeitas a perturbações persistentes**. 2014. Dissertação de Mestrado (Mestre em Engenharia Elétrica) – Universidade Federal de Sergipe, Sergipe, 2014.

SILVA, M. Z. **Estudo da influência do desgaste na falha prematura de componentes de linhas de ancoragem**. 2016. Dissertação de Mestrado (Ciências Mecânicas) – Universidade de Brasília, Faculdade de Tecnologia Departamento de Engenharia Mecânica, Brasília, 2016.

SIQUEIRA, F. M. F. **Estratégia de Otimização de Processos com o Uso de Redes Neurais Artificiais**. 2021. Dissertação (Mestrado em Engenharia Química) - Programa de Pós-Graduação em Engenharia Química, Universidade Federal Fluminense, Niterói - RJ, 2021.

SRIVASTAVA, N. et al. **Dropout: a simple way to prevent neural networks from overfitting**. Journal of Machine Learning Research, v. 15, p. 1929–1958, 2014.

STANDLEY, Trevor et al. **Which tasks should you learn together in multi-task learning**. INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS. ICLR, 2020.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. 2. ed. Cambridge: MIT Press, 2018.

TANCREDI, T. P. **Otimização multidisciplinar distribuída aplicada a projetos de engenharia**. 2008. Tese (Doutorado em Engenharia Naval e Oceânica) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2008.

TOMERA, M. **A multivariable low speed controller for a ship autopilot with experimental results**. 2015. 20th International Conference on Methods and Models in Automation and Robotics (MMAR), Miedzyzdroje, Poland, 2015, pp. 17-22.

VALE, R. d. A. **Efeito da Carga de Prova na Curva de Fadiga do Gancho de Ancoragem para Conexão Remota em Amarras de Fundo**. 2011. Dissertação de Mestrado (Mestre em Engenharia Metalúrgica e de Materiais) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

VIEIRA, W. B. **Avaliação do sistema de ancoragem considerando o estiramento dos segmentos de poliéster**. 2022. Trabalho de Conclusão de Curso (Graduação em Engenharia Naval e Oceânica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

VIGLIO, J. E.; DI GIULIO, G. M.; FERREIRA, L. C. **Not all glitters in the black gold: uncertainties and environmental threats of the Brazilian pre-salt**. São Paulo, 2017. p. 21-38. Ambiente e Sociedade (Campinas), São Paulo, v.20, n.3, p.21-38, 2017.

WINSTON, W. L. **Operations Research: Applications and Algorithms**. 4. ed. Belmont: Thomson Brooks/Cole, 2009.

YEE, X. E.; MOHAMED, M. A. W.; MONTASIR, O. A. **Application of Artificial Neural Network on Health Monitoring of Offshore Mooring System**. In: 3rd International Symposium on Civil and Environmental Engineering (ISCEE 2020), 1-2 December 2020, Batu Pahat, Johor, Malaysia. IOP Conference Series: Materials Science and Engineering, Volume 1144, 2021.

## APÊNDICE A – Modelo Preditivo (Offset % a partir do neutro)

```
# =====
# 1) Importação de bibliotecas
# =====
import pandas as pd
import numpy as np
import random
import joblib
import tensorflow as tf
import matplotlib.pyplot as plt

from sklearn.model_selection import train_test_split, KFold,
GridSearchCV
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import r2_score, mean_squared_error,
mean_absolute_error

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, BatchNormalization
from tensorflow.keras.callbacks import EarlyStopping, ReduceLROnPlateau
from tensorflow.keras.optimizers import Adam, RMSprop
from tensorflow.keras import regularizers

from scikeras.wrappers import KerasRegressor

# =====
# 2) Fixando as seeds para reprodutibilidade
# =====
np.random.seed(42)
tf.random.set_seed(42)
random.seed(42)

# =====
# 3) Carregando os dados
# =====
dados = pd.read_csv('C:/Users/Computador/Desktop/Offset.csv')

# =====
# 4) Definindo entradas e saída
# =====
colunas_saida = ['Offset % a partir do neutro']
colunas_entrada = ['R12', 'R11', 'R10', 'R9', 'R8', 'R7', 'R6', 'R5',
'R4', 'R3', 'R2', 'R1', 'R24', 'R23', 'R22', 'R21', 'R20', 'R19', 'R18',
'R17', 'R16', 'R15', 'R14', 'R13', 'L12', 'L11', 'L10', 'L9', 'L8', 'L7',
'L6', 'L5', 'L4', 'L3', 'L2', 'L1', 'L24', 'L23', 'L22', 'L21', 'L20',
'L19', 'L18', 'L17', 'L16', 'L15', 'L14', 'L13', 'P12', 'P11', 'P10',
```

```

'P9', 'P8', 'P7', 'P6', 'P5', 'P4', 'P3', 'P2', 'P1', 'P24', 'P23',
'P22', 'P21', 'P20', 'P19', 'P18', 'P17', 'P16', 'P15', 'P14', 'P13']

entradas = dados[colunas_entrada]
saidas = dados[colunas_saida]

# =====
# 5) Divisão treino/teste
# =====
entradas_train, entradas_test, saidas_train, saidas_test =
train_test_split(
    entradas, saidas, test_size=0.2, random_state=42)

# =====
# 6) Normalização dos dados
# =====
scaler_entrada = MinMaxScaler()
scaler_saida = MinMaxScaler()

entradas_train_scaled = scaler_entrada.fit_transform(entradas_train)
saidas_train_scaled = scaler_saida.fit_transform(saidas_train)

# Salvando os escaladores
joblib.dump(scaler_entrada,
'C:/Users/Computador/Desktop/Modelos/scaler_entrada_1.pkl')
joblib.dump(scaler_saida,
'C:/Users/Computador/Desktop/Modelos/scaler_saida_1.pkl')

# =====
# 7) Definindo a função de criação da rede
# =====
def create_model(neurons=256, layers=4, dropout_rate=0.05,
l2_reg=0.0001,
                learning_rate=0.005, optimizer_choice='Adam',
input_shape=(76,)):

    if optimizer_choice == 'Adam':
        optimizer = Adam(learning_rate=learning_rate)
    else:
        optimizer = RMSprop(learning_rate=learning_rate)

    model = Sequential()
    model.add(Dense(neurons, input_shape=input_shape,
activation='relu',
                kernel_regularizer=regularizers.l2(l2=l2_reg)))
    model.add(BatchNormalization())

    for _ in range(layers - 1):
        model.add(Dense(neurons, activation='relu',

```

```

        kernel_regularizer=regularizers.l2(l2=l2_reg))
    model.add(Dropout(dropout_rate))
    model.add(BatchNormalization())

    model.add(Dense(1)) # Saída

    model.compile(optimizer=optimizer, loss='mean_squared_error')
    return model

# =====
# 8) Callbacks
# =====
early_stopping = EarlyStopping(monitor='loss', patience=20,
                                restore_best_weights=True)
reduce_lr = ReduceLROnPlateau(monitor='loss', factor=0.5, patience=10,
                                min_lr=1e-6)

# =====
# 9) K-Fold nos dados de treino (para GridSearchCV)
# =====
kf = KFold(n_splits=5, shuffle=True, random_state=42)

# =====
# 10) GridSearchCV
# =====
param_grid = {
    'model__neurons': [32, 64, 128],
    'model__layers': [2, 3, 4],
    'model__dropout_rate': [0.05, 0.1],
    'model__l2_reg': [0.00001, 0.0001],
    'model__learning_rate': [0.005, 0.001],
    'model__optimizer_choice': ['Adam'],
    'batch_size': [32, 64, 128],
    'epochs': [350]
}

search = GridSearchCV(
    estimator=KerasRegressor(
        model=create_model,
        callbacks=[early_stopping, reduce_lr],
        input_shape=(entradas_train_scaled.shape[1],),
        verbose=0
    ),
    param_grid=param_grid,
    scoring='r2',
    cv=kf,
    n_jobs=-1)

search.fit(entradas_train_scaled, saidas_train_scaled.ravel())

```

```

print("\nMelhores hiperparâmetros encontrados:")
melhores_parametros = search.best_params_
for parametro, valor in melhores_parametros.items():
    print(f"{parametro}: {valor}")

print(f"\nMelhor R² médio (validação cruzada):
{search.best_score_:.4f}")

# =====
# 11) Avaliação no conjunto de teste
# =====
entradas_test_scaled = scaler_entrada.transform(entradas_test)
saidas_test_scaled = scaler_saida.transform(saidas_test)

previsoes = search.best_estimator_.predict(entradas_test_scaled)

# Desnormalização para visualização
desnormalizado_real =
scaler_saida.inverse_transform(saidas_test_scaled)
desnormalizado_prev =
scaler_saida.inverse_transform(previsoes.reshape(-1, 1))

r2 = r2_score(saidas_test_scaled, previsoes)
mse = mean_squared_error(saidas_test_scaled, previsoes)
mae = mean_absolute_error(saidas_test_scaled, previsoes)

print("\nMétricas para a saída: Offset % a partir do neutro")
print(f"R²: {r2:.4f}")
print(f"MSE: {mse:.4f}")
print(f"MAE: {mae:.4f}")

# =====
# 12) Gráfico de comparação
# =====
plt.figure(figsize=(8, 8))
plt.scatter(
    desnormalizado_real, desnormalizado_prev,
    facecolors='#1f5a99',
    edgecolors='#06172b',
    alpha=0.75, s=20
)

# Linha diagonal
min_val = min(desnormalizado_real.min(), desnormalizado_prev.min())
max_val = max(desnormalizado_real.max(), desnormalizado_prev.max())
plt.plot([min_val, max_val], [min_val, max_val], color='black',
linewidth=1.5)

```

```
# Eixos e aparência
plt.xlabel('Valores Reais')
plt.ylabel('Valores Previstos')
plt.title('Valores Reais vs Previstos')
plt.grid(True)
plt.tight_layout()
plt.show()

# =====
# 13) Salvamento do modelo final
# =====
search.best_estimator_.model_.save('C:/Users/Computador/Desktop/Modelos
/modelo_offset.h5')
print("Treinamento, avaliação e salvamento do modelo concluídos.")
```

Fonte: Elaborada pela autora (2024).

## APÊNDICE B – Primeira parte do código aplicado no Synapse.

```

# =====
# 1) Importação de bibliotecas
# =====
import pandas as pd
from tensorflow.keras.models import load_model
from sklearn.preprocessing import MinMaxScaler
import numpy as np
import joblib
import sys
import io
import time

# =====
# 2) Carregando os escaladores de entrada e saída separadamente
# =====
scaler_entrada_1 =
joblib.load('C:/Users/Computador/Desktop/Modelos/scaler_entrada_1.pkl')
scaler_entrada_2 =
joblib.load('C:/Users/Computador/Desktop/Modelos/scaler_entrada_2.pkl')
scaler_entrada_3 =
joblib.load('C:/Users/Computador/Desktop/Modelos/scaler_entrada_3.pkl')
scaler_entrada_4 =
joblib.load('C:/Users/Computador/Desktop/Modelos/scaler_entrada_4.pkl')

scaler_saida_1 =
joblib.load('C:/Users/Computador/Desktop/Modelos/scaler_saida_1.pkl')
scaler_saida_2 =
joblib.load('C:/Users/Computador/Desktop/Modelos/scaler_saida_2.pkl')
scaler_saida_3 =
joblib.load('C:/Users/Computador/Desktop/Modelos/scaler_saida_3.pkl')
scaler_saida_4 =
joblib.load('C:/Users/Computador/Desktop/Modelos/scaler_saida_4.pkl')

# =====
# 3) Carregando os modelos para as quatro saídas
# =====
modelo_saida1 =
load_model('C:/Users/Computador/Desktop/Modelos/modelo_offset.h5')
modelo_saida2 =
load_model('C:/Users/Computador/Desktop/Modelos/modelo_delta.h5')
modelo_saida3 =
load_model('C:/Users/Computador/Desktop/Modelos/modelo_tensão.h5')
modelo_saida4 =
load_model('C:/Users/Computador/Desktop/Modelos/modelo_carga.h5')

```

```
# =====  
# 4) Colunas de identificação  
# =====  
colunas_ID = ['R12', 'R11', 'R10', 'R9', 'R8', 'R7', 'R6', 'R5', 'R4',  
'R3', 'R2', 'R1', 'R24', 'R23', 'R22', 'R21', 'R20', 'R19', 'R18',  
'R17', 'R16', 'R15', 'R14', 'R13', 'L12', 'L11', 'L10', 'L9', 'L8',  
'L7', 'L6', 'L5', 'L4', 'L3', 'L2', 'L1', 'L24', 'L23', 'L22', 'L21',  
'L20', 'L19', 'L18', 'L17', 'L16', 'L15', 'L14', 'L13', 'P12', 'P11',  
'P10', 'P9', 'P8', 'P7', 'P6', 'P5', 'P4', 'P3', 'P2', 'P1', 'P24',  
'P23', 'P22', 'P21', 'P20', 'P19', 'P18', 'P17', 'P16', 'P15', 'P14',  
'P13']
```

Fonte: Elaborada pela autora (2024).

## APÊNDICE C – Segunda parte do código aplicado no Synapse.

```

# =====
# Definir os valores de entrada
# =====
entradas_valores = np.array([R12, R11, R10, R9, R8, R7, R6, R5, R4, R3,
R2, R1, R24, R23, R22, R21, R20, R19, R18, R17, R16, R15, R14, R13,
L12, L11, L10, L9, L8, L7, L6, L5, L4, L3, L2, L1, L24, L23, L22, L21,
L20, L19, L18, L17, L16, L15, L14, L13, P12, P11, P10, P9, P8, P7, P6,
P5, P4, P3, P2, P1, P24, P23, P22, P21, P20, P19, P18, P17, P16, P15,
P14, P13], dtype=np.float64)

# =====
# Criar um DataFrame com os valores de entrada
# =====
entradas_df = pd.DataFrame([entradas_valores], columns=colunas_ID)

# =====
# Normalizar os dados de entrada para cada modelo usando o scaler
correspondente
# =====

entradas_scaled_1 = scaler_entrada_1.transform(entradas_df)
entradas_scaled_2 = scaler_entrada_2.transform(entradas_df)
entradas_scaled_3 = scaler_entrada_3.transform(entradas_df)
entradas_scaled_4 = scaler_entrada_4.transform(entradas_df)

# =====
# Fazer previsões para cada uma das saídas separadamente
# =====
previsao_saida1_scaled = modelo_saida1.predict(entradas_scaled_1)
previsao_saida2_scaled = modelo_saida2.predict(entradas_scaled_2)
previsao_saida3_scaled = modelo_saida3.predict(entradas_scaled_3)
previsao_saida4_scaled = modelo_saida4.predict(entradas_scaled_4)

# =====
# Desnormalizar cada uma das previsões separadamente
# =====
previsao_saida1 =
scaler_saida_1.inverse_transform(previsao_saida1_scaled)
previsao_saida2 =
scaler_saida_2.inverse_transform(previsao_saida2_scaled)
previsao_saida3 =
scaler_saida_3.inverse_transform(previsao_saida3_scaled)
previsao_saida4 =
scaler_saida_4.inverse_transform(previsao_saida4_scaled)

```

```
# =====  
# Extrair os valores das previsões desnormalizadas  
# =====  
Offset_percent = previsao_saida1[0, 0]  
Delta_yaw = previsao_saida2[0, 0]  
Tensao = previsao_saida3[0, 0]  
percent_de_cargas = previsao_saida4[0, 0]  
  
# =====  
# Exibir os resultados  
# =====  
print(f"Offset % a partir do neutro: {Offset_percent}")  
print(f"Delta yaw neutro: {Delta_yaw}")  
print(f"Tensão % nas linhas: {Tensao}")  
print(f"% de carga nas âncoras: {percent_de_cargas}")
```

Fonte: Elaborada pela autora (2024).