



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS FLORIANÓPOLIS
ENGENHARIA CIVIL

Vinicius Borges Balansin

**Procedimento baseado em otimização para a definição
geométrica de projetos preliminares de dolphins de
amarração realizado por aprendizado de máquina em
Python**

Florianópolis
2024

Vinicius Borges Balansin

**Procedimento baseado em otimização para a definição
geométrica de projetos preliminares de dolphins de
amarração realizado por aprendizado de máquina em
Python**

Trabalho de Conclusão de Curso de Graduação em Engenharia Civil do Campus Florianópolis da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Engenharia Civil.

Orientador: Prof. Leandro Fleck Fadel Miguel, Dr.

Florianópolis

2024

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

Balansin, Vinicius Borges
Procedimento baseado em otimização para a definição
geométrica de projetos preliminares de dolphins de
amarração realizado por aprendizado de máquina em Python /
Vinicius Borges Balansin ; orientador, Leandro Fleck
Fadel Miguel, 2024.
93 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia Civil, Florianópolis, 2024.

Inclui referências.

1. Engenharia Civil. 2. Aprendizado de Máquina. 3.
Método dos Elementos Finitos. 4. Dolphins. 5. Gaussiana.
I. Miguel, Leandro Fleck Fadel. II. Universidade Federal
de Santa Catarina. Graduação em Engenharia Civil. III.
Título.

Vinicius Borges Balansin

**Procedimento baseado em otimização para a definição
geométrica de projetos preliminares de dolphins de
amarração realizado por aprendizado de máquina em
Python**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de Bacharel em Engenharia Civil e aprovado em sua forma final pelo Curso de Engenharia Civil.

Florianópolis, 12 de dezembro de 2024.

Banca Examinadora:

Prof. Leandro Fleck Fadel Miguel, Dr.
Orientador
Universidade Federal de Santa Catarina

Prof. Jano d'Araujo Coelho, Dr.
Avaliador
Universidade Federal de Santa Catarina

Eng. Mateus Prado Lone
Avaliador
INFRAS Engenharia

Dedico este trabalho aos meus pais e a toda a minha família.

Agradecimentos

Agradeço, primeiramente, à minha família por todo o apoio que sempre me deram. Estar onde estou só foi possível graças a vocês. À minha mãe, Maria, e ao meu pai, Ronaldo, expresso minha eterna gratidão pelo amor e pela luta diária para que eu pudesse realizar meu sonho de infância: estudar engenharia em uma universidade federal.

À minha namorada, Isabela, agradeço por seu amor e por estar ao meu lado em todas as etapas difíceis que enfrentei, sendo uma mulher forte e inteligente, com quem desejo trilhar um futuro de mãos dadas. Também sou grato a Francisco, Geovana e Rute por me acolherem e pelo apoio incondicional que me proporcionaram.

Minha gratidão ao CORE, especialmente ao Professor Leandro F. F. Miguel e ao Professor Rafael H. Lopez, por acreditarem no meu trabalho e por guiarem e incentivarem meu aperfeiçoamento. Agradeço também a Thiago M. F. e Gabriel P. A. pelos ensinamentos, suporte e materiais que foram fundamentais para o desenvolvimento deste trabalho. Um agradecimento especial a Pedro G. e Leonardo M., por me acompanharem nos estudos de uma área tão desafiadora.

Aos meus amigos Anthony, Carlos, Eduardo, George, Gustavo, Henrique, João, Júlio, Lucas, Pedro e Vinicius, sou profundamente grato pelo companheirismo, pelos momentos de descontração e pela amizade, que, mesmo com a distância, me animam e motivam todos os dias.

Agradeço à INFRAS Engenharia por ser um guia na busca pela excelência profissional. Minha gratidão especial vai ao Engenheiro Mateus L., que me ajudou a compreender temas portuários e estruturais, além de compartilhar conhecimentos valiosos que foram essenciais para a realização deste trabalho.

*“Se eu vi mais longe, foi por estar sobre ombros de gigantes”
(Isaac Newton , 5 de fevereiro de 1676)*

Resumo

Neste trabalho, desenvolveu-se um algoritmo metaheurístico que utiliza aprendizado de máquina para a otimização estrutural eficiente de um dolphin de amarração. Implementado em Python, o algoritmo emprega a Interface de Programação de Aplicação (API) do software de simulação de engenharia em elementos finitos ANSYS para obter dados de tensão, deformação e rotação dos elementos da estrutura. A função objetivo considera o peso total da estrutura como critério de otimização. As variáveis de projeto incluem as direções, inclinações e pontos iniciais das estacas do dolphin de amarração, respeitando limites geométricos e normativos. A aprendizagem por reforço é utilizada para classificar a função objetivo de N amostras topológicas distintas. Já o Backtracking Search Algorithm (BSA) em conjunto com a Kriging-based Efficient Global Optimization (EGO) refina os parâmetros gerados, visando alcançar um valor ótimo global. Devido aos resultados satisfatórios deste estudo, é demonstrada a eficácia do uso de algoritmos metaheurísticos e aprendizado de máquina na otimização de estruturas de engenharia, destacando vantagens de integrar ferramentas computacionais avançadas com metodologias inovadoras de análise estrutural.

Palavras-chave: Método dos Elementos Finitos. Aprendizagem de Máquina. Dolphins. Krigagem. Modelagem Numérica. Otimização. Gaussiana.

Abstract

In this work, a metaheuristic algorithm that utilizes machine learning for the efficient structural optimization of a mooring dolphin was developed. Implemented in Python, the algorithm employs the Application Programming Interface (API) of the finite element engineering simulation software ANSYS to obtain stress, strain, and rotation data of the structural elements. The objective function considers the total weight of the structure as an optimization criterion. The design variables include the directions, inclinations, and starting points of the piles of the mooring dolphin, respecting geometric and normative limits. Reinforcement learning is used to classify the objective function of N distinct topological samples. Meanwhile, the Backtracking Search Algorithm (BSA) combined with Kriging-based Efficient Global Optimization (EGO) refines the generated parameters, aiming to achieve a global optimum value. Due to the satisfactory results of this study, the effectiveness of using metaheuristic algorithms and machine learning in the optimization of engineering structures is demonstrated, highlighting the advantages of integrating advanced computational tools with innovative structural analysis methodologies.

Keywords: Finite Elements Method. Machine Learning. Dolphins. Kriging. Numerical Modeling. Optimization. Gaussian.

Lista de figuras

Figura 1 – Projeto conceitual de Terminal Marítimo de Petróleo.	19
Figura 2 – Projeto típico de <i>dolphin</i> de amarração.	20
Figura 3 – Arranjos típicos de berços portuários.	25
Figura 4 – Disposição das estacas no modelo estrutural do <i>dolphin</i>	26
Figura 5 – Seção transversal da estaca utilizada no modelo. .	30
Figura 6 – Diagrama de esforços aplicados na estaca.	30
Figura 7 – Perfil lateral das estacas com engastamento fictício.	32
Figura 8 – Perfil lateral considerando o solo.	33
Figura 9 – Fluxograma da função objetivo proposta.	34
Figura 10 – Localização das estacas na laje.	36
Figura 11 – Ângulos horizontais considerados (α_H).	37
Figura 12 – Ângulos verticais considerados (α_v).	38
Figura 13 – Fluxograma do modelo desenvolvido.	41
Figura 14 – Esforços internos da estrutura	45
Figura 15 – Deslocamento da estrutura	45
Figura 16 – Representação do espelhamento das estacas N_1 e N_2 em relação ao eixo X	47
Figura 17 – Propriedades geométricas da seção transversal da estaca.	48
Figura 18 – Modelagem das estacas com nós conectados no topo e na base.	49
Figura 19 – Exemplo de disposição das estacas em um <i>dolphin</i> .	50
Figura 20 – Discretização da laje do <i>dolphin</i>	51
Figura 21 – Nós da laje do <i>dolphin</i>	52
Figura 22 – Cabeços de amarração.	53
Figura 23 – Cabeço de amarração no modelo de elementos finitos.	54
Figura 24 – Distanciamento adequado entre estacas.	55

Figura 25 – Colisão entre estacas no plano Z	55
Figura 26 – Distribuição das cargas horizontais simuladas. . . .	57
Figura 27 – Configuração das cargas gravitacionais aplicadas. .	58
Figura 28 – Fluxograma ilustrativo do funcionamento do algoritmo EGO.	61
Figura 29 – Exemplo de distribuição aleatória de Γ_n em 2D. . .	62
Figura 30 – Exemplo de distribuição aleatória de Γ_n em 3D. . .	63
Figura 31 – Exemplo de um Quadrado Latino (Quadrado Latino <i>Latin Square</i> (LS)) de ordem $n = 4$	64
Figura 32 – Representação genérica de um plano de amostragem Γ_n em uma matriz $n \times n$	64
Figura 33 – Distribuição dos planos amostrais em um LHS. . . .	66
Figura 34 – Empilhamento dos planos amostrais.	67
Figura 35 – Exemplo de distribuição Γ_k em 2D utilizando o LHS.	69
Figura 36 – Exemplo de distribuição Γ_k em 3D utilizando o LHS.	69
Figura 37 – Hipérbole com linha de tendência e intervalo de incerteza (Quantil de 90%).	73
Figura 38 – Γ_k com pontos de preenchimento (2D).	74
Figura 39 – Γ_k com pontos de preenchimento (3D).	75
Figura 40 – Superfície de predição gerada pelo processo de regressão Gaussiana.	75
Figura 41 – Estrutura resultante com base no ϵ -guia (Vista 1).	79
Figura 42 – Estrutura resultante com base no ϵ -guia (Vista 2).	79
Figura 43 – Geometria ϵ otimizada (Vista 1).	83
Figura 44 – Geometria ϵ otimizada (Vista 2).	83
Figura 45 – Evolução dos custos históricos - Método BSA (1 ^a Iteração).	84
Figura 46 – Evolução dos custos históricos - Método EGO. . .	84
Figura 47 – Evolução dos custos históricos - Método BSA (2 ^a Iteração).	85

Figura 48 – Estrutura do pior caso observada no 13º experi-
mento (vista 1). 85

Figura 49 – Estrutura do pior caso observada no 13º experi-
mento (vista 2). 86

Lista de quadros

Quadro 1 – Normas técnicas aplicadas no projeto.	27
Quadro 2 – Formato da extração de dados do modelo.	44

Lista de tabelas

Tabela 1 – Distribuição de valores por tipo de solo.	27
Tabela 2 – Coeficientes K e razão de atrito (α) para diferentes tipos de solo.	28
Tabela 3 – Correção para resistência lateral (F1) e Correção para resistência de ponta (F2) para diferentes tipos de estacas.	29
Tabela 4 – Limites de Referência Considerados no Estudo . .	33
Tabela 5 – <i>Constraints</i> adotadas para o modelo.	42
Tabela 6 – Propriedades dos Materiais.	46
Tabela 7 – Sequência A002860: Número de Quadrados Latinos (LS) possíveis de ordem n	65
Tabela 8 – W_P Mínimo Obtido em Cada Experimento.	80
Tabela 9 – Tempo de Processamento (em Segundos).	81

Lista de abreviaturas e siglas

ABNT	Associação Brasileira de Normas Técnicas
alpha	Razão de atrito
API	<i>Application Programming Interface</i>
BS6349	Norma Britânica
BSA	<i>Backtracking Search Algorithm</i>
BSI	British Standards Institution
EA	<i>Evolutionary Algorithm</i>
EGO	<i>Kriging-based Efficient Global Optimization</i>
EI	<i>Expected Improvement</i>
F1	Correção para resistência lateral
F2	Correção para resistência de ponta
K	Coefficiente de recalque vertical
LHS	Amostragem por Hipercubo Latino <i>Latin Hypercube Sampling</i>
LS	Quadrado Latino <i>Latin Square</i>
MAPDL	<i>Mechanical Ansys Parametric Design Language</i>
MEF	Métodos dos Elementos Finitos
ML	<i>Machine Learning</i>
NBR	Norma Brasileira Regulamentadora
NSPT	Número de Golpes Padrão do ensaio SPT (<i>Standard Penetration Test</i>)

Lista de símbolos

f_{ck}	resistência característica do concreto
E	Módulo de elasticidade
I	Momento de inércia
γ	Fator de correção
ϵ	Tensor de deformação
W_p	Métrica avaliativa
d	Diâmetro da seção circular
ν	Coefficiente de Poisson
ρ	Densidade (kg/m ³)
Γ	Espaço de amostra
D	Distância euclidiana
μ	Média
σ	Variância
Ψ	Função de correlação
∇	Ruído Gaussiano (ou nugget)
$\Phi(\cdot)$	Função cumulativa da distribuição Gaussiana
$\Omega(\cdot)$	Densidade de probabilidade da distribuição Gaussiana

Sumário

1	INTRODUÇÃO	19
1.1	DEFINIÇÃO E USO DO DOLPHIN	19
1.2	ALGORITMOS METAHEURÍSTICOS E OTIMIZAÇÃO ESTRUTURAL	20
1.3	OBJETIVOS	22
1.3.1	Objetivo geral	22
1.3.2	Objetivos específicos	22
1.4	JUSTIFICATIVA DA IMPORTÂNCIA DO TEMA ABORDADO	23
2	REVISÃO BIBLIOGRÁFICA	24
2.1	DEFINIÇÃO E CONTEXTO	24
2.2	COMPONENTES E ESTRUTURAS	24
2.2.1	Materiais e construção	24
2.3	PERFIL DE SOLO CONSIDERADO	26
2.4	NORMAS, RESTRIÇÕES E VALORES DE REFERÊNCIA	27
2.4.1	Esforços axiais	28
2.4.1.1	Resistência do solo pela metodologia de Aoki e Velloso	28
2.4.2	Momento resultante	29
2.4.3	Deslocamento	31
2.4.4	Engastamento fictício	31
2.4.5	Restrições do modelo	33
3	MÉTODO	34
3.1	FUNÇÃO OBJETIVO	34
3.1.1	Parâmetros iniciais da função objetivo	35
3.1.2	Definição da função objetivo	39
3.2	ESPECIFICAÇÕES DO MODELO	40
3.2.1	Variáveis de restrição	42

3.2.2	Ações	43
3.2.3	Método dos elementos finitos	43
3.3	PROPRIEDADES DOS ELEMENTOS ESTRUTURAIS	46
3.4	ELEMENTOS ESTRUTURAIS EM $\mathbb{R}^3$	46
3.4.1	Estacas	47
3.4.2	Laje	51
3.4.3	Cabeço de amarração	52
3.5	RESTRIÇÕES GEOMÉTRICAS	54
3.6	AÇÕES APLICADAS AO SISTEMA	56
3.6.1	Cargas pontuais	56
3.6.2	Cargas permanentes	57
3.7	PARÂMETRO AVALIATIVO	58
3.8	INTRODUÇÃO AO <i>EFFICIENT GLOBAL OPTIMIZATION</i>	60
3.9	AMOSTRA INICIAL	61
3.9.1	Quadrado latino	63
3.9.2	Amostragem por Hipercubo Latino	65
3.9.2.1	Métrica de distância no LHS	67
3.9.2.2	Exemplos de amostragem com LHS	68
3.10	<i>KRIGING</i>	70
3.10.1	Covariância no <i>Kriging</i>	70
3.10.2	Modelo operacional simplificado	72
3.10.3	Exemplo de krigagem	72
3.11	PONTOS DE PREENCHIMENTO EM Γ	73
3.12	MELHORIA ESPERADA	76
3.13	BSA	77
3.13.1	Pseudo-código do BSA	77
4	RESULTADOS	78
4.1	PARÂMETROS ADOTADOS	78
4.2	RESULTADOS	78

4.2.1	Dados obtidos	80
5	CONCLUSÃO	87
	REFERÊNCIAS	89


1 Introdução

1.1 Definição e uso do dolphin


Dolphins são estruturas localizadas fora do cais, equipadas com um cabeço projetado para a amarração de embarcações (APPA, 2019). Sua função principal no contexto portuário é viabilizar tanto a amarração quanto a atracação de navios, fornecendo uma solução eficiente em situações onde a ampliação do cais não é viável. Essas estruturas desempenham um papel crucial na absorção de esforços horizontais gerados durante manobras portuárias.

Sustentados por estacas, os *dolphins* são projetados para resistir a forças horizontais intensas, características de aplicações portuárias. A superestrutura é geralmente construída em concreto armado, podendo ser pré-fabricada ou moldada *in loco*, dependendo das exigências específicas do projeto (Das et al., 2015). A Figura 1 ilustra um exemplo típico de distribuição de *dolphins* de amarração integrados a um terminal portuário. A Figura 2 apresenta um projeto típico de *dolphin*.

Figura 1 – Projeto conceitual de Terminal Marítimo de Petróleo.



Fonte: Adaptado de Das et al. (2015).

Figura 2 – Projeto típico de *dolphin* de amarração.

Fonte: Adaptado de Ryu et al. (2000).

1.2 Algoritmos metaheurísticos e otimização estrutural

Os algoritmos metaheurísticos são métodos computacionais iterativos que buscam a melhoria progressiva de soluções candidatas, baseando-se em regras predefinidas para otimizar problemas complexos (Rao, 1996). Esses algoritmos simulam o processo de tomada de decisão humana, explorando heurísticas — estratégias que auxiliam na descoberta e decisão em situações de incerteza ou restrições computacionais. Em essência, essas técnicas mecanizam o poder de decisão humano, permitindo a exploração de grandes espaços de solução de forma eficiente e inteligente.

Os algoritmos metaheurísticos têm se destacado como ferramentas amplamente aplicadas em diversas áreas da engenharia, como transporte, materiais, geotecnia e estruturas. Na otimização estrutural, esses métodos são particularmente úteis para lidar com problemas

que envolvem um grande número de variáveis interdependentes, abrangendo desde a escolha de materiais e dimensões dos componentes até a definição da topologia e geometria de estruturas. No caso específico da obtenção de arranjos ideais de estacas, a complexidade do problema torna os algoritmos metaheurísticos indispensáveis. Eles permitem a exploração eficiente do espaço de soluções, oferecendo alternativas viáveis mesmo em cenários onde métodos tradicionais são limitados ou impraticáveis devido ao elevado custo computacional necessário para testar múltiplos casos.

Para auxiliar na definição da geometria inicial de projetos de *dolphins*, foi desenvolvido um procedimento baseado em otimização geométrica. Neste trabalho, utilizou-se o método *Kriging-based Efficient Global Optimization* (EGO) como base para o processo de otimização. Esse método foi escolhido devido à sua capacidade de reduzir a necessidade de múltiplas avaliações de resultados, enquanto mantém um alto grau de precisão (Gandomi et al., 2015).

As análises estruturais foram desenvolvidas em Python, utilizando a *Application Programming Interface* (API) do software ANSYS Mechanical APDL. A integração do EGO foi realizada com o auxílio das bibliotecas NumPy, SciPy, PyTorch e Matplotlib, que proporcionaram suporte para cálculos numéricos, implementação de algoritmos metaheurísticos e visualização de resultados. Conforme Gramacy (2020), o EGO, juntamente com os procedimentos de análise, inferência e avaliação estrutural, deve ser adaptado para atender às especificidades do estudo. Essa adaptação garante uma abordagem robusta e personalizada, essencial para a obtenção de resultados esperados no problema proposto.

1.3 Objetivos

Nas seções abaixo estão descritos o objetivo geral e os objetivos específicos deste trabalho.

1.3.1 Objetivo geral

O objetivo deste trabalho é desenvolver um procedimento baseado em otimização geométrica para auxiliar na definição da geometria inicial de um *dolphin* de amarração, implementando um algoritmo metaheurístico integrado com o EGO, como ferramenta para minimizar os esforços internos da estrutura.

1.3.2 Objetivos específicos

- Desenvolver a modelagem estrutural e a análise automatizada, seguindo normas técnicas e aplicando o método dos elementos finitos em Python, utilizando o PyMAPDL, a API do *software* ANSYS *Mechanical Ansys Parametric Design Language* (MAPDL);
- Explicar o funcionamento e a aplicação do EGO no contexto do problema estudado;
- Implementar a otimização do problema proposto utilizando o algoritmo EGO como principal ferramenta;
- Comparar os resultados com dados elaborados manualmente e gerados pelo *Backtracking Search Algorithm* (BSA), garantindo precisão, confiabilidade e compatibilidade com o cenário idealizado em um projeto.

1.4 Justificativa da importância do tema abordado

O uso de métodos avançados de otimização na engenharia estrutural é essencial para a modernização da área, promovendo processos mais digitais e eficientes. Essas soluções computacionais ampliam a capacidade de engenheiros encontrarem alternativas inovadoras de forma ágil, combinando experiência prática com abordagens matemáticas. Assim, os modelos desenvolvidos tornam-se mais precisos e adaptados às demandas atuais, contribuindo para projetos economicamente efetivos.

2 Revisão Bibliográfica

2.1 Definição e contexto

Os *dolphins* são estruturas portuárias fundamentais para a atracação e amarração de navios. Suas características podem variar em tamanhos, formatos e materiais, adaptando-se às demandas específicas de cada projeto (Gaythwaite, 2016). Conforme Tsinker (2014), os *dolphins* de amarração são geralmente posicionados atrás da linha de atracação, sendo projetados para suportar as forças provenientes das amarrações das embarcações.

A otimização de estruturas *offshore* é essencial para aumentar a eficiência dos projetos, ajustando parâmetros geométricos e materiais para soluções mais econômicas. Com base na metodologia proposta por Ryu et al. (2000), o método EGO como ferramenta para minimizar os esforços internos de um *dolphin*. A abordagem integra o Métodos dos Elementos Finitos (MEF) com o *Machine Learning* (ML) para otimizar a distribuição das estacas e garantir a viabilidade estrutural.


2.2 Componentes e estruturas

2.2.1 Materiais e construção

Os materiais utilizados nos *dolphins* são especificados conforme o tipo e a finalidade da estrutura. Neste estudo, utilizam-se o concreto com f_{ck} de 20 MPa para estacas e f_{ck} de 40 MPa para lajes, ambos com agregado de calcário, em conformidade com a Norma Brasileira Regulamentadora (NBR) da Associação Brasileira de Normas Técnicas (ABNT), incluindo as normas NBR 8800 (ABNT, 2008) e NBR 6118 (2023). O diâmetro adotado segue boas práticas e considera a disponibilidade de empresas capazes de elaborar estacas com essas dimensões no mercado.

Apesar de oferecer excelente resistência a impactos, os *dolphins* apresentam desafios significativos na concepção, locação e execução (Gaythwaite, 2016). Esses desafios estão relacionados à adequação das estruturas às condições locais e demandas operacionais. A Figura 3 ilustra arranjos típicos de berços portuários, onde a geometria é determinante para a eficiência e segurança do sistema.

Figura 3 – Arranjos típicos de berços portuários.




Fonte: Adaptado de Gaythwaite (2016).

Quando é necessário acessar grande parte do comprimento da embarcação para o manuseio de cargas, o navio é atracado ao longo de um cais ou píer. Nesses casos, os cabeços de amarração são distribuídos uniformemente para atender às operações usuais de um porto. Por outro lado, quando o manuseio exige apenas a amarração, opta-se pelo uso de *dolphins*, evitando a ampliação do cais, que seria uma solução

mais onerosa.

Neste trabalho, o modelo estrutural do *dolphin* foi desenvolvido com base no *layout* proposto por Carioti et al. (1961). Ele é composto por cinco estacas e um cabeço de amarração. A Figura 4 apresenta a disposição das estacas no modelo estrutural adotado.

Figura 4 – Disposição das estacas no modelo estrutural do *dolphin*.



2.3 Perfil de solo considerado

Neste estudo, foi adotado um perfil de solo idealizado, não representativo de condições reais. Essa simplificação tem como objetivo simular procedimentos práticos de projeto, utilizando um modelo de solo pouco coesivo (arenoso). As informações do Número de Golpes Padrão do ensaio SPT (*Standard Penetration Test*) (NSPT) foram extraídas da NBR 6122 (ABNT, 2022) e utilizadas para simular um cenário simplificado, conforme apresentado na Tabela 1. Este perfil de solo tem como objetivo fornecer uma base prática e teórica para a

análise estrutural e o desenvolvimento do estudo, sem a pretensão de gerar um projeto final.

Tabela 1 – Distribuição de valores por tipo de solo.

Cota (m)	Tipo de Solo	N _{SPT}
-14,7	Areia	25
-15,7	Areia	25
...	...	...
-46,7	Areia	25
-47,7	Rocha sã	-

2.4 Normas, restrições e valores de Referência

Para a definição das restrições de forma, foram utilizados valores de referência baseados em normas técnicas e artigos amplamente aplicados em estudos da área. O projeto de *dolphins* rígidos neste estudo segue as recomendações das normas da ABNT NBR 8800, NBR 6122, NBR 6118 (2008; 2022; 2023) e da Norma BS6349:2 da British Standards Institution (BSI) (2010), que estabelecem critérios para deslocamentos, forças axiais e momentos admissíveis, conforme apresentado na Tabela 1. Os valores de referência consideram critérios de exequibilidade local, limitações de equipamentos e a facilidade na execução das estacas e demais componentes da estrutura.

Quadro 1 – Normas técnicas aplicadas no projeto.

Norma	Descrição
<i>ABNT NBR 6118:2023</i>	Estruturas de concreto armado e protendido
<i>ABNT NBR 8800:2008</i>	Estruturas de aço e mistas de aço e concreto
<i>ABNT NBR 6122:2022</i>	Projeto e execução de fundações
<i>BS6349:2 BSI (2010)</i>	Critérios de projeto para estruturas marítimas

2.4.1 Esforços axiais

2.4.1.1 Resistência do solo pela metodologia de Aoki e Velloso

Com base na metodologia de Aoki e Velloso (1975), os valores de resistência do solo foram calculados com base no perfil de solo adotado (Tabela 1). Os parâmetros utilizados incluem o Coeficiente de recalque vertical (K) e a Razão de atrito (α), apresentados na Tabela 2. Além da Correção da resistência lateral ($F1$) e Correção da resistência de ponta ($F2$), cujos valores são apresentados na Tabela 3.

Tabela 2 – Coeficientes K e razão de atrito (α) para diferentes tipos de solo.

Solo	K (MPa)	α (%)
Areia	1,00	1,4
Areia siltosa	0,80	2,0
Areia siltoargilosa	0,70	2,4
Areia argilosa	0,60	3,0
Areia argilossiltosa	0,50	2,8
Silte	0,40	3,0
Silte arenoso	0,55	2,2
Silte arenoargiloso	0,45	2,8
Silte argiloso	0,23	3,4
Silte argiloarenoso	0,25	3,0
Argila	0,20	6,0
Argila arenosa	0,35	2,4
Argila arenossiltosa	0,30	2,8
Argila siltosa	0,22	4,0
Argila siltoarenosa	0,33	3,0

Fonte: Adaptado de Aoki e Velloso (1975).

Tabela 3 – F1 e F2 para diferentes tipos de estacas.

Tipo de Estaca	F ₁	F ₂
Vibrada Concreto	2,25	4,50
Centrifugada Concreto	2,25	4,50
Madeira	1,75	3,50
Metálica	1,75	3,50
Strauss	3,00	6,00
Escavada	3,00	6,00
Estação	3,00	6,00
Apiloadada	2,50	5,00
Franki	2,50	5,00
Raiz	2,00	4,00
Hélice Contínua	2,00	4,00

Fonte: Adaptado de Aoki e Velloso (1975).

2.4.2 Momento resultante

Com o auxílio do *software PCALC*, foi calculado o momento resultante para uma estaca com perfil de 1 m de diâmetro e 4% de armadura, correspondente a 38 barras de 32 mm, conforme ilustrado na Figura 5. Os esforços máximos de cálculo foram determinados a partir do diagrama de esforços, conforme ilustrado na Figura 6.

Figura 5 – Seção transversal da estaca utilizada no modelo.



Fonte: *Software PCALC.*

Figura 6 – Diagrama de esforços aplicados na estaca.

Fonte: *Software PCALC.*

Para a otimização do modelo, foi estabelecido um valor de referência para o momento de $2500 \text{ kN} \cdot \text{m}$, definido como uma *constraint* no modelo de análise. Esse valor foi adotado para assegurar a segurança e a eficiência do projeto, representando uma simplificação no dimensionamento das estacas.

2.4.3 Deslocamento

De acordo com a Norma Britânica (BS6349) (BSI, 2010), o deslocamento horizontal permitido para estacas é de 100 mm. Esse limite foi adotado como critério de *constraint* no modelo estrutural analisado neste estudo.

2.4.4 Engastamento fictício

Com base no método de Davisson e Robinson (1965), foi adotado um engastamento fictício de comprimento L_s , calculado por meio da Equação 1:

$$L_s = \gamma \sqrt[n]{\frac{EI}{k}} \quad (1)$$

- Módulo de elasticidade (E) = $3.182 \cdot 10^{10} \text{ Pa}$
- Momento de inércia (I) = 0.049 m^4
- Coeficiente de recalque vertical (K) = $1.0 \cdot 10^6 \text{ N/m}^3$
- Fator de correção (γ) = 1.8 (adimensional)
- Expoente $n = 5$ (adimensional)

As dimensões consideradas para o modelo e a estaca real foram:

- Cota livre acima do solo (L_{Livre}): 14.7 m;
- Comprimento fictício para engastamento (L_s): 5.3 m;
- Comprimento cravado real (L_{Cravado}): 34 m;
- Comprimento total da estaca no modelo ($L_{\text{Livre}} + L_s$): 20 m;
- Comprimento total da estaca real ($L_{\text{Livre}} + L_{\text{Cravado}}$): 48.7 m.

Para o modelo proposto, o engastamento do elemento foi adotado a 20 m, conforme os cálculos realizados. Optou-se pelo método de engastamento fictício para simplificação dos cálculos do MEF. A consideração de um modelo com molas para representar o solo em camadas demandaria outra abordagem, que não será detalhada neste trabalho. As Figuras 7 e 8 apresentam, respectivamente, os perfil adotados para este estudo e o perfil de cravação das estacas.

Figura 7 – Perfil lateral das estacas com engastamento fictício.





Figura 8 – Perfil lateral considerando o solo.



2.4.5 Restrições do modelo

As restrições (*constraints*) adotadas no modelo foram baseadas em critérios técnicos e limites de referência amplamente utilizados na literatura e normas técnicas. Esses limites, apresentados na Tabela 4, guiam a verificação estrutural, assegurando a sua viabilidade e a segurança.

Tabela 4 – Limites de Referência Considerados no Estudo


Parâmetro	Valor Limite
Esforço axial máximo de compressão	5500 kN
Esforço axial máximo de tração	2000 kN
Momento Resultante	2500 kN · m
Deslocamento limite	100 mm

3 Método

3.1 Função objetivo

No contexto do ML, a função objetivo é a base que orienta o modelo na otimização de seus resultados a partir de valores de entrada ϵ . Ela avalia o desempenho do modelo gerando um valor representativo W_p que reflete sua eficácia, servindo como um guia para ajustes nos parâmetros de entrada ϵ . Em problemas de programação linear, onde há uma função objetivo a ser otimizada, é fundamental estudar o comportamento das soluções conforme os coeficientes de custo da função objetivo são parametrizados (Saaty e Gass, 1954). A funcionalidade da função objetivo proposta pode ser visualizada no fluxograma apresentado na Figura 9.

Figura 9 – Fluxograma da função objetivo proposta.



O objetivo deste trabalho é desenvolver um procedimento baseado em otimização para auxiliar na definição da geometria inicial de um *dolphin* de amarração. A função objetivo desempenha um papel central nesse processo, orientando a determinação da geometria ideal (a partir do ϵ ideal) para minimizar esforços internos e deslocamentos. O método utiliza o EGO como ferramenta de otimização, cuja descrição detalhada será apresentada nas seções seguintes deste capítulo.

3.1.1 Parâmetros iniciais da função objetivo

Um tensor é uma entidade matemática que generaliza os conceitos de escalar, vetor e matriz para n dimensões. Neste trabalho, o tensor $\varepsilon_{\text{tensor}}$ é definido conforme mostrado na Equação 2:

$$\varepsilon_{\text{tensor}} = \begin{pmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,11} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,11} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n,1} & x_{n,2} & \cdots & x_{n,11} \end{pmatrix} \quad (2)$$

Cada elemento $x_{i,j}$ representa uma variável específica, onde i indica o conjunto de valores (linha da matriz) a ser utilizado na função objetivo. A função objetivo é parametrizada por um vetor ϵ , que contém variáveis geométricas das estacas, descritas como:

- $X_{i,1}$: Coordenada X da estaca N_1 (x_1);
- $X_{i,2}$: Coordenada Y da estaca N_1 (y_1);
- $X_{i,3}$: Ângulo Vertical da estaca N_1 (α_{V_1});
- $X_{i,4}$: Ângulo Horizontal da estaca N_1 (α_{H_1});
- $X_{i,5}$: Coordenada X da estaca N_2 (x_2);
- $X_{i,6}$: Coordenada Y da estaca N_2 (y_2);
- $X_{i,7}$: Ângulo Vertical da estaca N_2 (α_{V_2});
- $X_{i,8}$: Ângulo Horizontal da estaca N_2 (α_{H_2});
- $X_{i,9}$: Coordenada X da estaca N_3 (x_3);
- $X_{i,10}$: Ângulo Vertical da estaca N_3 (α_{V_3});
- $X_{i,11}$: Ângulo Horizontal da estaca N_3 (α_{H_3}).

Essas variáveis permitem ao modelo ajustar a posição e a orientação das estacas. Os valores possíveis do vetor ϵ variam no intervalo $[0, 1]$ (limite inferior e superior), representando uma normalização matemática. Para facilitar a conversão desses valores para os limites reais do problema, foram estabelecidos os seguintes limites superiores e inferiores, representados pelas Figuras 10, 11 e 12:

Figura 10 – Locação das estacas na laje.






Figura 11 – Ângulos horizontais considerados (α_H).

Figura 12 – Ângulo verticais considerados (α_v).

Onde:

- Coordenadas x : $[0, 5.5]$;
- Coordenadas y : $[0.5, 2.5]$;
- Ângulo Horizontal (α_H): $[-45^\circ, 225^\circ]$;
- Ângulo Horizontal da Estaca N_3 : $[0^\circ, 180^\circ]$ (arredondamento binário para valores discretos);
- Ângulo Vertical (α_V): $[-75^\circ, -90^\circ]$.

Essas transformações garantem que o vetor ϵ mapeie corretamente os valores normalizados para os valores reais dentro dos limites estabelecidos. O vetor de um conjunto padrão pode ser representado pela Equação 3:

$$\epsilon = (x_1, y_1, \alpha_{V_1}, \alpha_{H_1}, x_2, y_2, \alpha_{V_2}, \alpha_{H_2}, x_3, \alpha_{V_3}, \alpha_{H_3}) \quad (3)$$

3.1.2 Definição da função objetivo

A função objetivo é uma expressão matemática utilizada para avaliar a qualidade de soluções em problemas de otimização. Ela estabelece um critério de desempenho, indicando o quão bem uma solução atende aos objetivos almejados. No contexto deste estudo, a função objetivo é projetada para minimizar esforços internos e deslocamentos no *dolphin*. A função objetivo simplificada é definida pela Equação 4.

$$F_{\text{Objetivo}}(\epsilon) = W_P \quad (4)$$


A análise da função objetivo busca compreender como a variabilidade nos coeficientes responsáveis pela concepção estrutural influencia a solução obtida. Essa abordagem permite ajustes mais precisos, evitando repetições de processos trabalhosos e garantindo melhor adaptação as condicionantes em que a estrutura está inserida. O foco está na exploração de parâmetros que minimizem os esforços internos e deslocamentos, guiando uma tomada de decisão mais rápida, eficaz e personalizada. O EGO baseia-se em conceitos metaheurísticos que exploram o espaço de soluções. Sua aplicação tem como objetivo determinar os parâmetros geométricos ideais para o *dolphin*, alinhando a eficiência estrutural e adaptabilidade da estrutura.

3.2 Especificações do modelo

O modelo do *dolphin* desenvolvido neste trabalho é composto por quatro grupos principais: as propriedades dos elementos estruturais (laje e pilares), a localização dos elementos no espaço $\mathbb{R}^3$ (obtida por meio de ϵ), as restrições geométricas e as ações aplicadas ao conjunto. Esses grupos foram organizados com o objetivo de assegurar as características essenciais do sistema, representar condições típicas de projeto e se alinhar à metodologia de cálculo empregada pelo ANSYS.

A abordagem proposta automatiza o procedimento de cálculo manual descrito por Remery e Van Oortmerssen (1973), integrando o MEF e ML para definir a geometria inicial e calcular os esforços internos do *dolphin*. Um algoritmo em Python realiza iterações contínuas, evitando etapas manuais repetitivas e descartando cenários com desempenho insatisfatório (Meta-heurística). O fluxo geral do modelo é apresentado na Figura 13.

Figura 13 – Fluxograma do modelo desenvolvido.



Fonte: Adaptado de Remery e Van Oortmerssen, 1973.

3.2.1 Variáveis de restrição

As variáveis de restrição (*constraints*) utilizadas neste projeto foram baseadas nas normas da ABNT e BSI, conforme descrito na Tabela 1. Esses limites foram adotados para assegurar a viabilidade estrutural e a conformidade do modelo com as práticas consagradas em projetos similares, podendo ser visualizados na Tabela 5.

Tabela 5 – *Constraints* adotadas para o modelo.

Parâmetro	Valor Limite
Esforço axial máximo de compressão ($F_{\text{comp.}}$)	5500 kN
Esforço axial máximo de tração ($F_{\text{tens.}}$)	2000 kN
Momento Resultante Limite ($M_{\text{lim.}}$)	2500 kN · m
Deslocamento Limite ($U_{\text{lim.}}$)	100 mm

Além das restrições de esforços internos e deslocamento, foram consideradas limitações construtivas específicas, como a sequência executiva e os limites de distanciamento das estacas ($2,5d$), conforme a NBR 6122:2022. Adotou-se um limite de 4% de armadura nos elementos, de modo que, ao somar as áreas de aço da laje e da estaca nos nós da estrutura, o total atingiu 8%, em conformidade com a NBR 6118:2023. Adicionalmente, respeitou-se um critério facultativo de espaçamento mínimo entre estacas de $1,5d$.

É importante ressaltar que não há uma norma específica para estruturas do tipo *dolphin* de amarração. A NBR 19782 fornece diretrizes gerais aplicáveis a estruturas portuárias, mas não foi utilizada como referência neste estudo. Por essa razão, critérios complementares foram adotados para assegurar uma geometria coerente. Os trabalhos de Carioti et al. (1961) e Ryu et al. (2000) serviram como guias principais para a modelagem e o desenvolvimento do presente trabalho.

3.2.2 Ações

As ações aplicadas na estrutura foram classificadas em dois grupos principais:

- **Cargas permanentes (G):**
 - Peso próprio da laje;
 - Peso próprio das estacas.
- **Cargas pontuais (Q):**
 - Forças horizontais induzidas pelas amarras do navio.

Com base na combinação dessas ações, é gerada uma envoltória de esforços internos que será utilizada na avaliação da estrutura e obtenção do W_p . A abordagem foca nos cenários mais críticos de esforços internos e deslocamentos, garantindo a segurança e eficiência do projeto. Detalhamentos sobre a obtenção desses esforços serão apresentado na subseção seguinte.

3.2.3 Método dos elementos finitos

O MEF é amplamente utilizado na engenharia estrutural devido à sua capacidade de resolver problemas complexos de forma eficiente. Ele fornece soluções aproximadas para sistemas estruturais sob diversas condições de carregamento e geometria, sendo especialmente útil para simular cenários variados de comportamento estrutural. Neste trabalho, o MEF foi implementado utilizando a linguagem de programação *Python* integrada ao software ANSYS. Essa combinação permitiu a automação de todas as etapas do processo de análise estrutural linear, desde a aplicação de cargas até a geração de malhas e extração dos resultados.

Modelos individuais foram gerado para cada combinação de carga, considerando diferentes valores de ϵ . Esses modelos geraram informações sobre esforços internos, momentos fletores e deslocamentos, que foram consolidados em uma envoltória de esforços. Essa abordagem orientou a função objetivo para encontrar o valor global ótimo de W_p , considerando todas as condições analisadas.

O Quadro 2 apresenta a maneira como os dados são extraídos dos modelos ANSYS para cada estaca. Os valores incluem esforços axiais de compressão e tração, momentos fletores e deslocamentos máximos observados em cada análise. A visualização das Figuras 14 e 15 ilustra os principais parâmetros utilizados na análise. Esses resultados fornecem uma base consistente para avaliar a eficiência estrutural e o comportamento da estrutura em diferentes cenários.

Quadro 2 – Formato da extração de dados do modelo.

Estaca	$F_{x_{\text{Result.}C}}$	$F_{x_{\text{Result.}T}}$	$M_{\text{Result.}}$	$U_{\text{Desloc.}}$
1	$F_{x_{c_1}}$	$F_{x_{t_1}}$	M_{r_1}	U_1
2	$F_{x_{c_2}}$	$F_{x_{t_2}}$	M_{r_2}	U_2
3	$F_{x_{c_3}}$	$F_{x_{t_3}}$	M_{r_3}	U_3
...	...	...	...	...
n	$F_{x_{c_n}}$	$F_{x_{t_n}}$	M_{r_n}	U_n

Os resultados incluem os seguintes parâmetros:

- $F_{\text{Result.}C}$: esforços axiais resultantes de compressão;
- $F_{\text{Result.}T}$: esforços axiais resultantes de tração;
- $M_{\text{Result.}}$: momentos fletores resultantes;
- $U_{\text{Desloc.}}$: deslocamentos máximos observados.

Figura 14 – Esforços internos da estrutura





Figura 15 – Deslocamento da estrutura



3.3 Propriedades dos elementos estruturais

A estrutura é composta por uma laje com dimensões de $6\text{ m} \times 6\text{ m}$, espessura de $1,5\text{ m}$, e cinco estacas com 20 m de comprimento e 1 m de diâmetro. Esses elementos foram modelados no ANSYS MAPDL, considerando as propriedades físicas dos materiais utilizados e as características geométricas projetadas. As propriedades dos materiais empregadas no modelo estão apresentadas na Tabela 6.

Tabela 6 – Propriedades dos Materiais.

Propriedade	Laje (C40)	Estaca (C20)
Módulo E_{ci} (Pa)	31875.76	22539.57
Coefficiente de Poisson (ν)	0.3	0.3
Densidade ρ (kg/m^3)	2500	2500

O módulo de elasticidade inicial (E_{ci}) foi determinado com base no f_{ck} do concreto, conforme as diretrizes da *NBR 6118*. Para concretos com $f_{ck} \leq 50\text{ MPa}$, o E_{ci} é calculado pela Equação 5, que considera o coeficiente α_E associado ao tipo de agregado. Neste trabalho, adotou-se concreto com agregado calcário ($\alpha_E = 0,9$), assegurando a correta integração das propriedades materiais ao modelo estrutural.

$$E_{ci} = \alpha_E \cdot 5600 \cdot \sqrt{f_{ck}} \quad (5)$$

3.4 Elementos estruturais em $\mathbb{R}^3$

A geometria dos elementos estruturais é definida a partir dos valores de ϵ , que determinam a orientação dos elementos no espaço tridimensional $\mathbb{R}^3$.

3.4.1 Estacas

Para a análise por MEF, as estacas foram modeladas como elementos estruturais lineares, resistentes a flexão, tração e compressão. O modelo no ANSYS inclui cinco estacas: duas laterais (N_1 e N_2), uma central (N_3) e duas simétricas (N_4 e N_5), geradas por espelhamento das laterais em relação ao eixo X . No processo de espelhamento, as coordenadas Y são invertidas, e os ângulos ajustados para garantir a simetria estrutural. A estaca N_3 é posicionada obrigatoriamente ao longo do eixo X ($Y = 0$), com orientação horizontal restrita a 0° ou 180° , assegurando a centralidade, como ilustrado na Figura 16. As propriedades geométricas da seção transversal da estaca tubular considerada no estudo estão apresentadas na Figura 17.

Figura 16 – Representação do espelhamento das estacas N_1 e N_2 em relação ao eixo X .






Figura 17 – Propriedades geométricas da seção transversal da estaca.



Fonte: *Ansys Mechanical APDL*

Para simplificar a análise, a base foi modelada com engastamento fictício, desconsiderando o efeito elástico do solo ao longo do comprimento cravado. As estacas são geradas dentro do ANSYS conectando dois nós (topo e base), com discretização em 10 sub-elementos ao longo de seu comprimento. Essa configuração é detalhada na Figura 18.

Figura 18 – Modelagem das estacas com nós conectados no topo e na base.



Fonte: *Ansys Mechanical APDL*

A partir de ϵ , são determinadas as coordenadas iniciais e as orientações verticais e horizontais das estacas, de forma análoga a um processo manual. Essas estacas não seguem um padrão estrutural fixo, sendo limitadas apenas por suas características geométricas e pelas restrições operacionais do equipamento de cravação, como a inclinação máxima permitida pelo martelo. Estruturas do tipo *dolphins* são usualmente posicionadas de forma a maximizar a disponibilidade de atracação durante o ano, minimizando o impacto das embarcações nas estruturas portuárias (Tsinker, 2014). A Figura 19 ilustra uma possível distribuição das estacas em um *dolphin*, destacando sua disposição simétrica e a geometria projetada.





Figura 19 – Exemplo de disposição das estacas em um *dolphin*.


3.4.2 Laje

A laje, também conhecida como *deck*, é responsável por transmitir as forças externas de projeto para a subestrutura, composta por estacas verticais e inclinadas (Ryu et al., 2000). Para a análise, a laje foi discretizada em uma malha com intervalos de 10 cm, garantindo maior precisão nas interações estruturais. A Figura 20 ilustra a discretização da laje empregada no *dolphin*.

Figura 20 – Discretização da laje do *dolphin*.



As coordenadas iniciais das estacas estão vinculadas aos pontos da malha discretizada, garantindo a conexão estrutural entre as estacas e a laje. Em cada ponto de conexão, é gerado um nó representando a amarração entre os dois elementos. A Figura 21 ilustra essa configuração.

Figura 21 – Nós da laje do *dolphin*.

3.4.3 Cabeço de amarração

Os cabeços de amarração instalados na laje são projetados para assegurar a fixação segura de navios atracados. Podem ser fabricados em metal (parafusados), e a escolha do material e modelo dependem das especificações do projeto. A Figura 22 apresenta diferentes tipos de cabeços, adaptados a finalidades específicas.




Figura 22 – Cabeços de amarração.

Descrição: (a) Cabeço em T; (b) Cabeço duplo; (c) Cabeço de liberação rápida; (d) Poste duplo; (e) Gancho de liberação rápida.

Fonte: Handbook of Port and Harbor Engineering: Geotechnical and Structural Aspects (2014).

O tamanho do bloco e o diâmetro do cabeço são determinados pela força de tração transmitida pelas linhas de amarração do navio (2014). Na análise por MEF, o cabeço foi modelado como um elemento análogo a uma estaca, com 1 m de altura ao longo do eixo Z , centralizado na laje, funcionando como ponto de aplicação de esforços horizontais. A configuração adotada é apresentada na Figura 23.




Figura 23 – Cabeço de amarração no modelo de elementos finitos.

3.5 Restrições geométricas

Algumas restrições (*constraints*) foram aplicadas para garantir a viabilidade geométrica da estrutura e o espaçamento adequado entre as estacas, evitando colisões. Penalizações na função W_p foram definidas para situações onde a distância entre os centros geométricos das estacas fosse insuficiente, avaliando essas restrições ao longo de todo o comprimento dos elementos estruturais. A Figura 24 ilustra um distanciamento adequado entre estacas, enquanto a Figura 25 apresenta um caso de colisão no plano Z .

Figura 24 – Distanciamento adequado entre estacas.





Figura 25 – Colisão entre estacas no plano Z.



A penalização associada ao descumprimento dessa restrição é calculada pela Equação 6:

$$W_{P1} = \frac{1,5 \cdot \text{Diâmetro da estaca}}{0,1 + \text{Distância entre estacas}} \quad (6)$$

Além disso, conforme o Anexo K da NBR 6122:2022, foi adotada uma restrição mínima de 2,5 vezes o diâmetro da estaca entre os centros geométricos das bases. A penalização correspondente a essa restrição é descrita pela Equação 7:

$$W_{P2} = \frac{2,5 \cdot \text{Diâmetro da estaca}}{0,1 + \text{Distância entre estacas}} \quad (7)$$


3.6 Ações aplicadas ao sistema

As ações aplicadas na estrutura foram classificadas em cargas pontuais e permanentes, com base nas características típicas de projetos de *dolphins*. Este estudo, devido às limitações de escopo, considerou as cargas de vento e ondas, priorizando as principais ações estruturais.

3.6.1 Cargas pontuais

As cargas pontuais foram simuladas como forças horizontais de 1000 kN, distribuídas uniformemente ao longo de um arco de 180 graus. Essas forças representam as ações aplicadas pelas amarras do navio. A configuração das cargas horizontais está ilustrada na Figura 26.


Figura 26 – Distribuição das cargas horizontais simuladas.



3.6.2 Cargas permanentes

As cargas permanentes foram representadas pela aplicação da aceleração gravitacional padrão ($9,81 \text{ m/s}^2$) sobre o modelo estrutural. Essas cargas incluem o peso próprio da laje e das estacas, sendo fundamentais para a análise dos esforços internos da estrutura. A configuração das ações gravitacionais é apresentada na Figura 27.

Figura 27 – Configuração das cargas gravitacionais aplicadas.



3.7 Parâmetro avaliativo

O parâmetro avaliativo W_p ideal é o valor almejado neste estudo, sendo determinado a partir de uma configuração ϵ que minimiza os esforços internos na estrutura. A disposição e a orientação das estacas são ajustadas para verificar se o modelo respeita as verificação de projeto e *constraints* definidas. Caso W_p receba penalizações antes da análise estrutural, como no caso de distâncias insuficientes entre os centros geométricos das estacas, a análise estrutural não é realizada, uma vez que as condições geométricas são consideradas inviáveis. Con-

forme descrito por Remery e Van Oortmerssen (1973) e ilustrado na Figura 13, projetos que violam restrições básicas são descartados.

O cálculo de W_p considera a envoltória dos esforços resultantes, assegurando que o *dolphin* atenda aos requisitos de desempenho estrutural em cenários críticos. Essa abordagem busca configurações que respeitem os limites normativos, promovendo eficiência e fornecendo soluções robustas para o projeto. A Equação 8 formaliza o cálculo de W_p , priorizando qualquer parâmetro que exceda os limites normativos, mesmo que outros estejam dentro dos valores aceitáveis. Essa formulação promove uma otimização uniforme, garantindo que todos os esforços sejam proporcionalmente minimizados.

$$W_P(\varepsilon) = \mathbf{Maior} \left\{ \frac{F_{\text{Result.}C} - F_{\text{comp.}}}{F_{\text{comp.}}}, \frac{F_{\text{Result.}T} - F_{\text{tens.}}}{F_{\text{tens.}}}, \frac{M_{\text{result.}} - M_{\text{lim.}}}{M_{\text{lim.}}}, \frac{U_{\text{desloc.}} - U_{\text{lim.}}}{U_{\text{lim.}}} \right\} \quad (8)$$

Onde:

- $F_{\text{Result.}C}$: Esforço axial resultante de compressão;
- $F_{\text{Result.}T}$: Esforço axial resultante de tração;
- $M_{\text{result.}}$: Momento fletor resultante no topo da estaca;
- $U_{\text{desloc.}}$: Deslocamento no topo da estaca;
- $F_{\text{comp.}} = 5500 \text{ kN}$: Limite de compressão;
- $F_{\text{tens.}} = 2000 \text{ kN}$: Limite de tração;
- $M_{\text{lim.}} = 2500 \text{ kN} \cdot \text{m}$: Limite de momento fletor;
- $U_{\text{lim.}} = 100 \text{ mm}$: Limite de deslocamento.

3.8 Introdução ao *Efficient Global Optimization*

O algoritmo EGO é uma abordagem de otimização bayesiana desenvolvida para problemas complexos que envolvem funções objetivo de alta demanda computacional, como aquelas modeladas por métodos de elementos finitos (Alves et al., 2022). Ele utiliza o modelo de interpolação *Kriging* como substituto e o *Expected Improvement* (EI) como função de aquisição. Essa metodologia reduz significativamente o número de avaliações computacionais necessárias no processo de otimização. Conforme descrito por Jones (2001), o funcionamento do método EGO pode ser resumido em três etapas principais:

1. Construção do plano de amostragem inicial utilizando um *space-filling design* baseado no Amostragem por Hipercubo Latino *Latin Hypercube Sampling* (LHS);
2. Desenvolvimento do metamodelo *Kriging*, que aproxima a função objetivo;
3. Adição de novos pontos de preenchimento (*infill points*) ao plano de amostragem inicial, seguida da atualização do metamodelo.

As etapas 2 e 3 são repetidas até que um critério de parada seja atingido. Esse critério pode estar relacionado a um número máximo de iterações, ao tempo computacional disponível ou a parâmetros de convergência específicos. A Figura 28 apresenta um fluxograma que ilustra o funcionamento geral do processo EGO.




Figura 28 – Fluxograma ilustrativo do funcionamento do algoritmo EGO.

3.9 Amostra inicial

A amostra inicial, representada por Γ_k , é composta por n_{inicial} pontos em um espaço de variáveis geométricas, conforme definido na Equação 9. Cada ϵ_i representa um ponto específico no espaço de entrada das variáveis geométricas, permitindo estruturar o plano de amostragem inicial de maneira sistemática e controlada.

$$\Gamma_k = \{\epsilon_1, \epsilon_2, \dots, \epsilon_{n_{\text{inicial}}}\} \quad (9)$$

Uma abordagem comum para gerar um plano de amostragem inicial é a utilização de uma distribuição aleatória. Contudo, essa técnica pode resultar em uma distribuição desuniforme de pontos, caracterizada pela formação de aglomerados e pela ausência de dados em determinadas regiões do espaço amostral (Gramacy, 2020). Esses problemas se tornam mais pronunciados em espaços de alta dimensão,

onde amostras aleatórias frequentemente falham em cobrir adequadamente regiões críticas. O comportamento indesejado de distribuições aleatórias é ilustrado nas Figuras 29 e 30, que mostram exemplos de planos amostrais gerados de forma aleatória em espaços Γ_n .

Figura 29 – Exemplo de distribuição aleatória de Γ_n em 2D.





Figura 30 – Exemplo de distribuição aleatória de Γ_n em 3D.

Para superar as limitações das distribuições aleatórias, este trabalho adota o LHS. Essa técnica assegura uma cobertura mais uniforme do espaço amostral, mitigando os problemas de subamostragem e aumentando a eficiência da análise. A aplicação do LHS será detalhada nas próximas seções.

3.9.1 Quadrado latino

Antes de introduzir o método LHS, é fundamental compreender o conceito base que sustenta sua construção: o LS. Esse conceito matemático é utilizado para gerar planos de amostragem uniformes, otimizando a distribuição de pontos no espaço amostral. A aplicação

do LS minimiza lacunas e redundâncias nos dados, aumentando a eficiência, especialmente em espaços multidimensionais.

Conforme Forrester et al. (2008), um LS de ordem n é definido por uma matriz $n \times n$, onde cada variável aparece exatamente uma vez em cada linha e coluna. Essa organização garante uma distribuição uniforme das projeções dos dados em diferentes dimensões, característica crucial para problemas de otimização complexos. Um exemplo de LS de ordem $n = 4$, utilizando os valores A, B, C e D, é apresentado na Figura 31.

Figura 31 – Exemplo de um Quadrado Latino (LS) de ordem $n = 4$.



A	B	C	D
B	C	D	A
C	D	A	B
D	A	B	C

O LS aplicado a planos de amostragem pode ser representado por uma matriz $n \times n$, onde $V_{i \times j}$ indica a posição de cada valor de amostragem no espaço Γ . Essa estrutura permite uma organização de dados multidimensionais, como ilustrado na Figura 32.

Figura 32 – Representação genérica de um plano de amostragem Γ_n em uma matriz $n \times n$.

$$\begin{pmatrix} V_{1 \times 1} & V_{1 \times 2} & V_{1 \times 3} & \dots & V_{1 \times n} \\ V_{2 \times 1} & V_{2 \times 2} & V_{2 \times 3} & \dots & V_{2 \times n} \\ V_{3 \times 1} & V_{3 \times 2} & V_{3 \times 3} & \dots & V_{3 \times n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ V_{n \times 1} & V_{n \times 2} & V_{n \times 3} & \dots & V_{n \times n} \end{pmatrix}$$

À medida que a ordem n aumenta, o número de combinações possíveis de LS cresce exponencialmente, conforme ilustrado na Tabela 7. Esse crescimento evidencia a complexidade de gerar planos de amostragem representativos em espaços de alta dimensão. A escala desse desafio é destacada pelos valores apresentados na Tabela 7.

Tabela 7 – Sequência A002860: Número de Quadrados Latinos (LS) possíveis de ordem n .

n	Número de Quadrados Latinos possíveis
1	1
2	2
3	12
4	576
5	161,280
6	812,851,200
7	61,479,419,904,000
8	108,776,032,459,082,956,800
9	5,524,751,496,156,892,842,531,225,600
10	9,982,437,658,213,039,871,725,064,756,920,320,000
11	776,966,836,171,770,144,107,444,346,734,230,682,311,065,600,000

Fonte: Adaptado de Sloane (2003).

Devido à complexidade crescente, o LS enfrenta desafios práticos ao ser aplicado em espaços de alta dimensão. Para lidar com essas limitações, métodos otimizados como o LHS foram desenvolvidos. O LHS combina os princípios do LS com algoritmos avançados, garantindo a geração de amostras mais eficientes e representativas, como será detalhado na próxima seção.

3.9.2 Amostragem por Hipercubo Latino

De acordo com Minasny e McBratney (2006), o método LHS é uma extensão do conceito de LS para espaços multidimensionais. Essa

técnica foi desenvolvida para amostrar n valores de uma distribuição definida para cada variável, garantindo uma cobertura uniforme do espaço amostral. O LHS reduz de forma significativa a formação de lacunas ou redundâncias nos dados, um problema frequentemente observado em amostragens aleatórias.


Cada variável ϵ é dividida em n intervalos equiprováveis, sendo um valor selecionado aleatoriamente dentro de cada intervalo (Carré et al., 2007). Essa abordagem promove a estratificação em todas as dimensões do espaço, assegurando maior representatividade e eficiência do plano amostral. A Figura 33 apresenta os planos amostrais de um exemplo de LHS em $4 \times 4 \times 4$.

Figura 33 – Distribuição dos planos amostrais em um LHS.

Plano amostral 1	Plano amostral 2
$\begin{pmatrix} A & B & C & D \\ B & C & D & A \\ C & D & A & B \\ D & A & B & C \end{pmatrix}$	$\begin{pmatrix} B & C & D & A \\ C & D & A & B \\ D & A & B & C \\ A & B & C & D \end{pmatrix}$
Plano amostral 3	Plano amostral 4
$\begin{pmatrix} C & D & A & B \\ D & A & B & C \\ A & B & C & D \\ B & C & D & A \end{pmatrix}$	$\begin{pmatrix} D & A & B & C \\ A & B & C & D \\ B & C & D & A \\ C & D & A & B \end{pmatrix}$

O empilhamento tridimensional dos planos amostrais demonstra como o LHS organiza os dados em camadas para garantir uniformidade em espaços multidimensionais. Esse processo é ilustrado na Figura 34, evidenciando a consistência das amostras geradas.

Figura 34 – Empilhamento dos planos amostrais.



Embora amostragens aleatórias possam satisfazer critérios de estratificação multidimensional, não garantem uniformidade no espaço amostral. O LHS supera essa limitação, promovendo cobertura uniforme em todas as dimensões. Contudo, é fundamental avaliar a qualidade do LHS para identificar amostras satisfatórias e não ideais, garantindo o desempenho ideal do método (Forrester et al., 2008).

3.9.2.1 Métrica de distância no LHS

A avaliação da qualidade dos hipercubos latinos depende crucialmente da métrica de distância utilizada. A distância D_p , mede a separação euclidiana entre dois pontos no espaço e é definida pela Equação 10:

$$D_p(\epsilon_{i_1}, \epsilon_{i_2}) = \left(\sum_{j=1}^k \left| \epsilon_{i_1}^j - \epsilon_{i_2}^j \right|^p \right)^{1/p} \quad (10)$$

Onde:

- $p = 2$ para a métrica Euclidiana

Seja $D_1, D_2 \dots, D_n$ a lista de distâncias únicas entre todos os pares de pontos no plano Γ_k . Definindo J_n como o número de pares de pontos separados pela distância d_j . Segundo Morris e Mitchell (1995), o melhor plano Γ_k é aquele que:

- Maximiza a distância mínima D_1 ;
- Minimiza o número de pares J_1 que compartilham a menor distância d_1 ;
- Maximiza sucessivamente as distâncias $D_2 \dots, D_n$.

Essas propriedades promovem um elevado grau de dispersão entre os pontos no espaço amostral, assegurando ao mesmo tempo a uniformidade da cobertura. Essa abordagem melhora a qualidade do plano de amostragem, fundamental para aplicações que exigem representatividade robusta em alta dimensão (Morris e Mitchell, 1995).

3.9.2.2 Exemplos de amostragem com LHS

A aplicação do LHS pode ser visualizada nos planos de amostragem Γ_k , com representações em 2D e 3D. Esses exemplos demonstram como o método distribui os pontos de maneira uniforme em cada dimensão, garantindo uma cobertura homogênea do espaço amostral. Essa abordagem evita lacunas e redundâncias, assegurando maior representatividade e eficiência, mesmo em cenários de alta dimensionalidade. Na Figura 35, observa-se um plano Γ_k em 2D, onde os pontos estão uniformemente distribuídos ao longo de dois eixos. De forma semelhante, a Figura 36 apresenta a distribuição em 3D, destacando o alinhamento uniforme em todas as dimensões.

Figura 35 – Exemplo de distribuição Γ_k em 2D utilizando o LHS.





Figura 36 – Exemplo de distribuição Γ_k em 3D utilizando o LHS.



3.10 Kriging

O *Kriging* é amplamente utilizado em modelagem estatística e probabilística, sendo especialmente eficaz para problemas onde o comportamento do sistema é parcialmente conhecido. Segundo Gramacy (2020), o método modela um conjunto finito de n observações como uma distribuição normal multivariada, permitindo a criação de estimativas robustas para sistemas complexos. Essa abordagem é amplamente adotada para construir metamodelos precisos, reduzindo custos computacionais em análises de engenharia e otimização.

O princípio central do *Kriging* é tratar a resposta em qualquer ponto do espaço Γ como uma realização de um processo estocástico estacionário. Esse processo é definido em função de ϵ , representando o valor da função desconhecida no ponto de interesse. Cada ponto no espaço é descrito por uma variável aleatória normal, caracterizada por uma média μ e uma variância σ^2 . Essa representação fornece não apenas uma estimativa do valor esperado, mas também as margens de erro associadas, permitindo maior confiabilidade nas previsões (Alves et al., 2024).

3.10.1 Covariância no *Kriging*

No *Kriging*, a proximidade entre os pontos de treinamento e de teste informa as previsões, permitindo que pontos próximos gerem dependências espaciais no modelo. A função de covariância, conforme destacado por Williams e Rasmussen (2006), é central nesse processo, pois captura a relação espacial entre os pontos, refletindo a estrutura da função modelada e equilibrando incertezas. A covariância entre dois pontos ϵ^i e ϵ^j no espaço Γ é dada por:

$$\text{Cov}[\epsilon^{(i)}, \epsilon^{(j)}] = \sigma^2 \Psi(\epsilon^{(i)}, \epsilon^{(j)}), \quad (11)$$

onde σ^2 é a variância do processo, e Ψ é a função de correlação que define a relação espacial. Essa formulação assegura previsões consistentes em regiões não amostradas.

Para kernels gaussianos, a matriz de correlação Ψ é definida por:

$$\Psi(\epsilon^{(i)}, \epsilon^{(j)}) = \exp\left(-\sum_{k=1}^q \alpha_k \left|\epsilon_k^{(i)} - \epsilon_k^{(j)}\right|^{p_k}\right),$$

onde:

- $\epsilon_k^{(i)}$ e $\epsilon_k^{(j)}$ são os valores das variáveis k -ésimas nos pontos i e j ;
- α_k é um parâmetro de escala que ajusta a intensidade da correlação;
- p_k é um expoente que define a suavidade da correlação.

Os parâmetros α_k e p_k podem ser estimados por meio da Estimativa de Máxima Verossimilhança (Jones, 2001). A partir desses parâmetros, o valor esperado $\hat{\mu}$ e a variância condicional σ_c^2 podem ser calculados pelas Equações 12 e 13, respectivamente:

$$\hat{\mu} = \frac{\mathbf{1}^T \Psi^{-1} \mathbf{W}_p}{\mathbf{1}^T \Psi^{-1} \mathbf{1}}, \quad (12)$$

$$\sigma_c^2 = \frac{(\mathbf{W}_p - \mathbf{1}\hat{\mu})^T \Psi^{-1} (\mathbf{W}_p - \mathbf{1}\hat{\mu})}{n_s}, \quad (13)$$

onde $\mathbf{1}$ é um vetor de uns e $\mathbf{W}_p$ contém as respostas observadas. A predição do Kriging em um novo ponto ϵ_u é dada por:

$$W_p(\epsilon_u) = \underbrace{\hat{\mu}}_{\text{Tendência}} + \underbrace{\mathbf{r}^T \Psi^{-1} (\mathbf{W}_p - \mathbf{1}\hat{\mu})}_{\text{Incerteza do modelo de substituição}}, \quad (14)$$

em que $\mathbf{r}$ é o vetor de correlação entre ϵ_u e os n_s pontos amostrados.

3.10.2 Modelo operacional simplificado

O modelo ideal, conforme apresentado anteriormente, pode ser simplificado operacionalmente, como sugerido por Gramacy (2020), na Equação 15:

$$W_P(\Gamma_k) = w(\Gamma_k) + \nabla \quad (15)$$

onde:

- $w(\Gamma_k) \sim \text{GP}$: um processo Gaussiano que modela a tendência suave da função, representando a estrutura subjacente do sistema;
- ∇ : um termo de "ruído Gaussiano" (ou *nugget*), que captura variações não explicadas pelo processo $w(\Gamma_k)$.

Neste contexto, $W_p(\Gamma_k)$ é o valor observado, resultante da combinação de $w(\Gamma_k)$, que descreve o comportamento esperado, e ∇ , que reflete incertezas e erros residuais do modelo. Essa abordagem simplificada mantém a representatividade do modelo original, reduzindo sua complexidade computacional.


3.10.3 Exemplo de krigagem

O ajuste do modelo de *Krigagem* é ilustrado com $\Gamma_{\text{hipérbole}}$, onde a matriz de covariância é construída com base na correlação entre os pontos ϵ . Esse modelo incorpora ∇ para capturar variações não modeladas explicitamente, estimando uma média predita e intervalos de confiança que representam a incerteza associada.

A Figura 37 apresenta o resultado desse ajuste, mostrando uma hipérbole suavizada com linha de tendência e intervalo de incerteza (Quantil de 90%). O modelo reflete o comportamento esperado da

função para novos dados, aproximando-se da hipérbole ideal, e serve como base para a função objetivo descrita no Capítulo 3.

Figura 37 – Hipérbole com linha de tendência e intervalo de incerteza (Quantil de 90%).



3.11 Pontos de preenchimento em Γ

A função objetivo é avaliada para cada ponto em Γ_k , gerando os resultados de W_p a partir das amostras iniciais. Após a aplicação do *Kriging*, n_{infill} pontos de preenchimento são introduzidos. Esse processo resulta no plano atualizado Γ , conforme a Equação 16, e nos respectivos valores de W_p , conforme a Equação 17.

$$\Gamma = \{\epsilon^{(1)}, \epsilon^{(2)}, \dots, \epsilon^{(n_{\text{inicial}} + n_{\text{infill}})}\}, \quad (16)$$

$$W_P = \{W_P^{(1)}, W_P^{(2)}, \dots, W_P^{(n_{\text{inicial}} + n_{\text{infill}})}\}, \quad (17)$$

onde n_{infill} é o número de pontos adicionados e n_{inicial} corresponde às amostras iniciais. A função penalidade associada ao modelo foi detalhada previamente na Equação 8. A introdução de *infill points*

melhora a precisão do modelo nas regiões menos amostradas, otimizando a eficiência da análise.

A cada iteração do EGO, o plano Γ é atualizado com os novos pontos. Essa atualização permite a modificação dinâmica dos parâmetros e reduz o esforço computacional, concentrando-se nas áreas mais relevantes do espaço amostral. O processo garante que W_p seja minimizado eficientemente, priorizando regiões com menor valor para orientar o processo de otimização.

As Figuras 38 e 39 ilustram a introdução de *infill points* em Γ_k , complementando as distribuições iniciais apresentadas nas Figuras 35 e 36.

Figura 38 – Γ_k com pontos de preenchimento (2D).





Figura 39 – Γ_k com pontos de preenchimento (3D).

A Figura 40 apresenta a superfície de predição gerada pelo processo EGO descrito neste capítulo. Essa superfície oferece uma estimativa probabilística média que orienta a busca pelo mínimo global da função objetivo.




Figura 40 – Superfície de predição gerada pelo processo de regressão Gaussiana.

3.12 Melhoria esperada

O critério de preenchimento do EGO baseia-se na incerteza do modelo *Kriging*, explorando a função de EI para otimizar a busca (Alves et al., 2024). A EI quantifica a melhoria potencial em um ponto de design ϵ , considerando sua predição $W_p(\epsilon)$ e variância $\sigma^2(\epsilon)$.

O objetivo é minimizar W_p , representando a envoltória de esforços e deslocamentos, enquanto pontos de preenchimento (*infill points*) são adicionados para reduzir incertezas e melhorar progressivamente o modelo. A melhor solução até a iteração atual, denotada pela Equação 18:

$$W_{P_{\max}} = \min\{W_P^{(1)}, W_P^{(2)}, \dots, W_P^{(n_s)}\}, \quad (18)$$

A melhoria potencial utilizada no método é dada pela Equação 19:

$$J(\epsilon) = \left[W_{P_{\max}} - \hat{W}_P(\epsilon) \right]. \quad (19)$$

Onde o EI é formalizado pela equação 20:

$$\begin{aligned} \text{EI}(\epsilon) = & \left[W_{P_{\max}} - \hat{W}_P(\epsilon) \right] \Phi \left(\frac{W_{P_{\max}} - \hat{W}_P(\epsilon)}{s(\epsilon)} \right) \\ & + s(\epsilon) \Omega \left(\frac{W_{P_{\max}} - \hat{W}_P(\epsilon)}{s(\epsilon)} \right), \end{aligned} \quad (20)$$

onde $\Phi(\cdot)$ e $\Omega(\cdot)$ representam, respectivamente, a função cumulativa e a função densidade de probabilidade da distribuição gaussiana. O processo segue iterativamente, adicionando pontos que maximizam EI, refinando o modelo até atingir um critério de parada (Jones et al., 1998).

3.13 BSA

A resolução de problemas de otimização com variáveis discretas, a não linearidade da função objetivo exige algoritmos metaheurísticos eficientes. Nesse contexto, o BSA pode ser empregado como referência para avaliar a eficácia do EGO, buscando minimizar a métrica W_p sob restrições de esforços e deslocamentos (Alves et al., 2024). O BSA é um *Evolutionary Algorithm* (EA) amplamente utilizado para problemas complexos e não diferenciáveis. Sua abordagem estocástica combina exploração e exploração do espaço de busca, identificando soluções próximas ao ótimo global (Civicioglu, 2013).

3.13.1 Pseudo-código do BSA

O adotando um modelo simplificado de Alves et al. (2024) o algoritmo BSA segue os passos descritos no pseudo-código abaixo:

1. Inicializar as populações P e P_hist
2. Para cada iteração até o limite máximo:
 - 2.1 Atualizar P_hist com embaralhamento aleatório
 - 2.2 Gerar matriz M e criar P_pert por mutação
 - 2.3 Avaliar aptidão de P_pert
 - 2.4 Substituir indivíduos menos aptos de P por P_pert
3. Retornar o melhor indivíduo de P

Fonte: Adaptado de alves2024hybrid

Este processo utiliza mutação e seleção dinâmicas, adaptando-se às características do problema e garantindo uma exploração balanceada do espaço de busca. Por ser um algoritmo completo, o BSA assegura a identificação de soluções válidas e é eficaz na aproximação de soluções ótimas (Van Beek, 2006).

4 Resultados

4.1 Parâmetros adotados

Os parâmetros adotados para a otimização foram:

- Tamanho da população inicial (n_{inicial}): 100.
- Número total de iterações (n_{infill}): 150.

Adicionalmente, valores sugeridos para o BSA em uma segunda execução foram calculados com base no número de avaliações da função objetivo (N_{OFES}), conforme definido na Equação 21, considerando o tempo total do EGO ($\text{Tempo}_{\text{EGO}}$) em relação ao tempo do BSA ($\text{Tempo}_{\text{BSA}}$):

$$N_{\text{OFES}_{\text{Sugerido}}} = \lfloor (n_{\text{inicial}} + n_{\text{infill}}) \cdot \frac{\text{Tempo}_{\text{EGO}}}{\text{Tempo}_{\text{BSA}}} \rfloor \quad (21)$$

Os valores para a segunda iteração do BSA foram calculados conforme as Equações 22 e 23:

$$\text{BSA } 2^{\text{a}} \text{ interação inicial} = \lfloor \log(N_{\text{OFES}}^2) \rfloor \quad (22)$$

$$\text{BSA } 2^{\text{a}} \text{ interação ninfillpoints} = \lceil \frac{N_{\text{OFES}}}{\log(N_{\text{OFES}}^2)} \rceil \quad (23)$$

4.2 Resultados

Os algoritmos de otimização foram executados em um computador com processador AMD Ryzen 7 5700X3D (8 núcleos, 16 threads). Em uma primeira rodada, foram utilizados os valores de população inicial e final definidos anteriormente tanto para o BSA quanto para o EGO. Em uma segunda iteração, o BSA foi reavaliado com os valores

atualizados de N_{OFEs} . Os resultados foram validados com base em um ϵ -guia, e as estruturas resultantes estão apresentadas nas Figuras 41 e 42.




Figura 41 – Estrutura resultante com base no ϵ -guia (Vista 1).




Figura 42 – Estrutura resultante com base no ϵ -guia (Vista 2).

4.2.1 Dados obtidos

Os resultados obtidos de W_P mínimo para cada experimento estão apresentados na Tabela 8, o tempo de processamento necessário para cada método está expresso na Tabela 9.

Tabela 8 – W_P Mínimo Obtido em Cada Experimento.

Experimento	BSA	EGO	BSA (2ª iteração)
1	0,00	-0,23	-0,16
2	-0,03	-0,01	-0,03
3	-0,06	-0,16	-0,32
4	-0,07	-0,23	-0,32
5	-0,03	-0,05	-0,27
6	-0,26	-0,25	-0,20
7	-0,03	-0,05	-0,27
8	-0,15	-0,28	-0,31
9	-0,06	-0,08	-0,35
10	-0,23	-0,17	-0,31
11	-0,26	-0,19	-0,36
12	-0,08	-0,15	-0,26
13	0,05	-0,12	0,00
14	-0,24	-0,24	-0,33
15	-0,14	-0,02	-0,31
16	-0,18	-0,01	-0,29
17	-0,10	-0,24	-0,29
18	-0,19	-0,21	-0,32
19	-0,02	-0,20	-0,31
20	-0,03	-0,31	-0,34

Continua na próxima página

Experimento	BSA	EGO	BSA (2ª iteração)
21	-0,03	-0,31	-0,34
22	-0,07	-0,17	-0,36
23	-0,20	-0,17	-0,31
24	-0,04	-0,28	-0,34
25	-0,13	-0,16	-0,26
26	-0,07	-0,06	-0,25
27	-0,18	-0,13	-0,31
28	-0,15	-0,13	-0,33
29	-0,21	-0,18	-0,17
30	-0,25	-0,11	-0,25

Tabela 9 – Tempo de Processamento (em Segundos).

Experimento	BSA	EGO	BSA (2ª iteração)
1	169,05	7407,10	2524,98
2	263,90	9872,58	256,60
3	347,20	9514,34	422,75
4	316,84	7630,75	5120,03
5	17,75	10308,95	26,30
6	611,71	7327,07	319,00
7	17,70	10308,90	26,30
8	763,20	8979,48	6287,10
9	448,54	8745,76	6664,00
10	434,24	8917,93	6800,00
11	295,62	7720,39	4996,70

Continua na próxima página

Experimento	BSA	EGO	BSA (2ª iteração)
12	278,10	8230,23	3632,30
13	206,31	7613,14	46,30
14	434,71	7321,41	6036,10
15	345,48	8343,91	8409,10
16	424,71	10837,28	13397,40
17	321,07	7921,64	7834,40
18	261,95	9546,37	9424,60
19	459,12	8155,68	8167,00
20	232,61	6832,60	6850,50
21	384,65	8648,01	8618,30
22	232,61	6832,60	6850,50
23	384,65	8648,01	8618,30
24	335,23	7987,99	5411,90
25	254,26	9983,68	2353,30
26	381,25	8517,38	6122,60
27	335,11	8310,53	8214,00
28	458,78	8608,65	10042,86
29	357,58	7624,70	3172,20
30	198,39	9000,40	4410,30

O melhor resultado foi obtido no 11º experimento, onde o W_P mínimo alcançou o valor de -0,36, com o menor tempo de 4996,70 segundos, conforme descrito nas Figuras 43 e 44.

É possível visualizar a evolução histórica dos valores de W_P para os métodos, conforme ilustrado nas Figuras 45, 46 e 47.




Figura 43 – Geometria ϵ otimizada (Vista 1).




Figura 44 – Geometria ϵ otimizada (Vista 2).

Figura 45 – Evolução dos custos históricos - Método BSA (1ª Iteração).




Figura 46 – Evolução dos custos históricos - Método EGO.





Figura 47 – Evolução dos custos históricos - Método BSA (2ª Iteração).




O pior desempenho foi observado no 13º experimento, com $W_P = 0,05$ e tempo de processamento de 206,31 segundos, resultando na estrutura mostrada nas Figuras 48 e 49.

Figura 48 – Estrutura do pior caso observada no 13º experimento (vista 1).



Figura 49 – Estrutura do pior caso observada no 13^o experimento (vista 2).



5 Conclusão

Neste trabalho, foi atingido o objetivo principal de desenvolver um procedimento baseado em otimização para definir a geometria inicial de um *dolphin* de amarração. A implementação dos métodos propostos proporcionou melhorias expressivas na distribuição dos esforços e na redução dos deslocamentos, evidenciando a influência dos parâmetros estudados na eficácia e no tempo de execução dos algoritmos.

Para atingir esses objetivos, foi desenvolvido e implementado um algoritmo metaheurístico integrado a metodologia EGO, cuja eficiência foi comparada à metodologia BSA. Ambos os métodos foram aplicados na otimização de uma mesma função objetivo, focando a obtenção da melhor disposição inicial das estacas.

A modelagem estrutural, desenvolvida por meio da API do MAPDL, possibilitou análises detalhadas dos esforços internos e deslocamentos estruturais, alinhadas às normas técnicas e metodologias consagradas. O EGO demonstrou um desempenho eficiente na solução do problema de otimização, sendo capaz de otimizar a geometria inicial do *dolphin*. Contudo, observou-se que essa abordagem apresentou tempo computacional mais elevado e resultados ligeiramente inferiores no que se refere à redução dos esforços internos, quando comparada ao BSA.

Por outro lado, o BSA destacou-se como a abordagem mais robusta e eficiente, especialmente em cenários onde o tempo computacional é um fator crítico. Essa metodologia apresentou resultados equivalentes ou superiores ao EGO, com um custo computacional significativamente menor. Esses resultados ressaltam a importância de explorar métodos alternativos, como os algoritmos evolutivos (EA), que se mostram altamente eficientes para problemas de otimização

estrutural.

Além disso, a superioridade dos resultados obtidos com o BSA em relação às soluções manuais (ϵ -guia) reafirma o potencial dos métodos computacionais e do aprendizado de máquina na busca por soluções otimizadas, robustas e eficientes no contexto da engenharia estrutural.

Por fim, os resultados alcançados demonstram que as técnicas propostas possuem grande potencial de aplicação prática em configurações reais de estruturas. Este estudo contribui de maneira significativa para a consolidação de ferramentas computacionais avançadas no campo da engenharia estrutural, reforçando a importância da integração entre otimização geométrica, modelagem numérica e aprendizado de máquina para a solução de problemas complexos e desafiadores.

REFERÊNCIAS

- ABNT (2008). *NBR 8800:2008 - Projeto e Execução de Estruturas de Aço e de Estruturas Mistas de Aço e Concreto de Edifícios*. Rio de Janeiro: ABNT.
- (2022). *NBR 6122:2022 - Projeto e execução de fundações*. Disponível em: <https://www.abntcatalogo.com.br/>. Rio de Janeiro: ABNT.
- (2023). *NBR 6118:2023 - Projeto de Estruturas de Concreto – Procedimento*. Rio de Janeiro: ABNT.
- Alves, G. P., A. Deichmann, L. F. Fadel Miguel, R. H. Lopez e V. V. B. Barros (2022). “Size, shape and layout optimization of mono-mast guyed transmission line towers”. Em: *Structural and Multidisciplinary Optimization* 65.7, pp. 201–223.
- Alves, G. P., L. F. F. Miguel, R. H. Lopez e H. Carvalho (2024). “A hybrid metaheuristic and machine learning approach for optimum design of transmission line tower families”. Em: *Fast Track Article, Taylor & Francis* 13.3, pp. 285–294.
- Aoki, N. e D. d. A. Velloso (1975). “An approximate method to estimate the bearing capacity of piles”. Em: *Proc., 5th Pan-American Conf. of Soil Mechanics and Foundation Engineering*. Vol. 1. International Society of Soil Mechanics e Geotechnical Engineering Buenos ... , pp. 367–376.

- APPA (2019). *Dicionário Básico Portuário*. 3ª edição. Atualizado em 2019. Paranaguá, Brasil: Administração dos Portos de Paranaguá e Antonina (APPA). Disp. em: <https://www.portosdoparana.pr.gov.br/Pagina/Dicionario-Basico->.
- BSI (2010). *BS6349*. Revisão de normas para obras marítimas e portuárias. London: British Standards Institution.
- Carioti, B., D. Elms e R. G. Robert (1961). *Dolphin Design*. in dolphin design: Bruno M. Carioti.
- Carré, F., A. B. McBratney e B. Minasny (2007). “Estimation and potential improvement of the quality of legacy soil samples for digital soil mapping”. Em: *Geoderma* 141.1-2, pp. 1–14.
- Civicioglu, P. (2013). “Backtracking search optimization algorithm for numerical optimization problems”. Em: *Applied Mathematics and computation* 219.15, pp. 8121–8144.
- Das, S., S. Kulkarni e M. Kudale (2015). “Design of Safe Mooring Arrangement for Large Oil Tankers”. Em: *Procedia Engineering* 116. 8th International Conference on Asian and Pacific Coasts (APAC 2015), pp. 528–534. ISSN: 1877-7058. DOI: <https://doi.org/10.1016/j.proeng.2015.08.322>. Disp. em: <https://www.sciencedirect.com/science/article/pii/S1877705815019773>.
- Davisson, M. e K. Robinson (1965). “Bending and buckling of partially embedded piles”. Em: *Soil Mech & Fdn Eng Conf Proc/Canada/*.

- Forrester, A., A. Sobester e A. Keane (2008). *Engineering Design via Surrogate Modelling: A Practical Guide*. John Wiley & Sons.
- Gandomi, A. H., A. R. Kashani, D. A. Roke e M. Mousavi (2015). “Optimization of retaining wall design using recent swarm intelligence techniques”. Em: *Engineering Structures* 103, pp. 72–84. ISSN: 0141-0296. DOI: <https://doi.org/10.1016/j.engstruct.2015.08.034>. Disp. em: <https://www.sciencedirect.com/science/article/pii/S0141029615005337>.
- Gaythwaite, J. W. (2016). “Design of marine facilities: Engineering for port and harbor structures”. Em: American Society of Civil Engineers.
- Gramacy, R. B. (2020). *Surrogates: Gaussian process modeling, design, and optimization for the applied sciences*. Chapman e Hall/CRC.
- Jones, D. R. (2001). “A Taxonomy of Global Optimization Methods Based on Response Surfaces”. Em: *Journal of Global Optimization* 21.4, pp. 345–383.
- Jones, D. R., M. Schonlau e W. J. Welch (1998). “Efficient global optimization of expensive black-box functions”. Em: *Journal of Global optimization* 13, pp. 455–492.
- Minasny, B. e A. B. McBratney (2006). “A conditioned Latin hypercube method for sampling in the presence of ancillary information”. Em: *Computers & geosciences* 32.9, pp. 1378–1388.

- Morris, M. D. e T. J. Mitchell (1995). “Exploratory designs for computational experiments”. Em: *Journal of statistical planning and inference* 43.3, pp. 381–402.
- Rao, S. S. (1996). *Engineering optimization: theory and practice*. John Wiley & Sons.
- Remery, G. e G. Van Oortmerssen (1973). “The mean wave, wind and current forces on offshore structures and their role in the design of mooring systems”. Em: *Offshore Technology Conference*. OTC, OTC-1741.
- Ryu, Y.-S., N. Lee, J.-T. Kim e H.-M. Cho (2000). “A practical procedure for the design optimization of pile-type substructure in a mooring dolphin”. Em: *Journal of the Computational Structural Engineering Institute of Korea* 13.3, pp. 285–294.
- Saaty, T. e S. Gass (1954). “Parametric objective function (part 1)”. Em: *Journal of the Operations Research Society of America* 2.3, pp. 316–319.
- Tsinker, G. (2014). *Handbook of Port and Harbor Engineering: Geotechnical and Structural Aspects*. Springer.
- Van Beek, P. (2006). “Backtracking search algorithms”. Em: *Foundations of artificial intelligence*. Vol. 2. Elsevier, pp. 85–134.
- Williams, C. K. e C. E. Rasmussen (2006). *Gaussian processes for machine learning*. Vol. 2. 3. MIT press Cambridge, MA.