

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Laura Grossi de Oliveira Souza

Inteligência Computacional aplicada na Otimização de Parques Eólicos
Offshore

Juiz de Fora

2026

Laura Grossi de Oliveira Souza

Inteligência Computacional aplicada na Otimização de Parques Eólicos
Offshore

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área: Sistemas de Energia.

Orientador: Prof. Ivo Chaves da Silva Júnior, Dr.

Juiz de Fora

2026

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Souza, Laura.

Inteligência Computacional aplicada na Otimização de Parques Eólicos
Offshore / Laura Grossi de Oliveira Souza. – 2026.

81 p.

Orientador: Ivo Chaves da Silva Júnior

Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, Faculdade
de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2026.

1. Parque Eólico Offshore. 2. Otimização. 3. Metaheurísticas. I. Chaves
da Silva Júnior, Ivo, orient. II. Título.

Laura Grossi de Oliveira Souza

Inteligência Computacional Aplicada na Otimização de Parques Eólicos Offshore

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestra em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica

Aprovada em 27 de fevereiro de 2026.

BANCA EXAMINADORA

Prof. Dr. Ivo Chaves da Silva Junior - Orientador
Universidade Federal de Juiz de Fora

Prof. Dr. Francisco Carlos Rodrigues Coelho
Universidade Federal de São João del-Rei

Prof. Dr. Leonardo Willer de Oliveira
Universidade Federal de Juiz de Fora

Juiz de Fora, 20/01/2026.



Documento assinado eletronicamente por **Ivo Chaves da Silva Junior, Professor(a)**, em 27/02/2026, às 17:43, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Francisco Carlos Rodrigues Coelho, Usuário Externo**, em 27/02/2026, às 22:05, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leonardo Willer de Oliveira, Professor(a)**, em 28/02/2026, às 11:05, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2831455** e o código CRC **873F6057**.

Dedico este trabalho a minha mãe Jaciara.

AGRADECIMENTOS

Gostaria de manifestar minha sincera gratidão a todas as pessoas e instituições que, de diferentes formas, contribuíram para que esta jornada de mestrado se concretizasse.

Em primeiro lugar, agradeço a Deus, cuja presença constante iluminou meu caminho, oferecendo força, serenidade e discernimento nos momentos mais desafiadores.

À minha mãe, registro meu amor e reconhecimento pelo apoio incansável, pela dedicação diária e por nunca permitir que eu desistisse dos meus objetivos. Aos meus avós, sou profundamente grata pela base de valores, pelo carinho e por sempre acreditarem no meu potencial. À minha irmã Marina, agradeço o companheirismo, a escuta e a parceria que tornaram este percurso mais leve. E até mesmo à minha gatinha Lola, cuja presença silenciosa se transformou em companhia, conforto e alegria ao longo dessa caminhada.

Expresso também meu especial agradecimento ao meu orientador, Prof. Ivo Chaves da Silva Júnior, por acreditar no meu trabalho, pelas oportunidades e pelas orientações sempre precisas. Sua orientação foi essencial para o desenvolvimento desta pesquisa.

Agradeço à Universidade Federal de Juiz de Fora, ao Programa de Pós-Graduação em Engenharia Elétrica (PPEE) e a todos os professores que contribuíram para minha formação acadêmica e científica.

Registro minha gratidão à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Instituto Nacional de Ciência e Tecnologia em Energia Elétrica (INERGE), pelo apoio financeiro e pelas oportunidades concedidas, fundamentais para o desenvolvimento deste trabalho.

Agradeço ainda ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo suporte institucional e incentivo à pesquisa.

Aos amigos que estiveram ao meu lado durante o mestrado, expresso minha sincera gratidão pelo apoio constante, pelas conversas que aliviaram os momentos difíceis, pela parceria nos estudos e pelas risadas que tornaram essa jornada mais leve.

A todos que, direta ou indiretamente, fizeram parte desta caminhada, deixo o meu mais sincero muito obrigada.

“A persistência é o caminho do êxito.”

(Richard Feynman)

RESUMO

Com o avanço da participação da energia eólica na matriz elétrica brasileira e mundial, torna-se cada vez mais relevante compreender os fatores que influenciam o desempenho dos parques eólicos. A otimização do *layout* das turbinas é fundamental para maximizar a geração de energia e reduzir as perdas decorrentes do efeito de esteira (*wake effect*), que diminui a velocidade do vento a jusante e aumenta a turbulência, impactando a potência extraída e a vida útil dos equipamentos. Entre os modelos propostos para representar esse fenômeno, o modelo de *Jensen* é amplamente utilizado devido à sua simplicidade e eficácia, sendo adotado neste trabalho como base para a modelagem do efeito de esteira. Dado o caráter complexo e não linear do problema de otimização do *layout* de parques eólicos, torna-se necessário empregar técnicas computacionais avançadas capazes de explorar eficientemente o espaço de busca. Neste estudo, avaliam-se três metaheurísticas de otimização global: *Bat Algorithm* (BA), *Grey Wolf Optimizer* (GWO) e *Multiverse Optimizer* (MVO). O objetivo principal é comparar o desempenho dessas técnicas na geração de *layouts* mais eficientes para parques eólicos *offshore*, utilizando exclusivamente o modelo de *Jensen* para a estimativa das perdas energéticas. A metodologia foi aplicada a dois parques eólicos *offshore* reais em fase de licenciamento ambiental pelo IBAMA, denominados Pedra Grande e Camocim, ambos localizados na costa nordestina do Brasil. Essa aplicação permitiu analisar as características específicas de cada parque, bem como avaliar detalhadamente a eficiência dos algoritmos quanto à qualidade das soluções, convergência e ganho energético obtido após a otimização dos *layouts*. Os resultados evidenciam diferenças marcantes no comportamento das três metaheurísticas. O estudo reforça a importância de escolher adequadamente a metaheurística para o problema de otimização do *layout* e demonstra que é possível obter melhorias na estimativa de energia gerada pelo parque.

Palavras-chave: Metaheurística. *wake effect*. Energia Eólica. Parques Eólicos *Offshore*. Otimização. *Layout*. *Bat Algorithm*. *Grey Wolf Optimizer*. *Multiverse Optimizer*.

ABSTRACT

With the growing share of wind energy in the Brazilian and global electricity matrix, it becomes increasingly important to understand the factors that influence the performance of wind farms. The optimization of the turbine *layout* is essential to maximize energy generation and reduce the losses caused by the wake effect, which decreases wind speed downstream and increases turbulence, affecting the extracted power and the lifespan of the equipment. Among the models proposed to represent this phenomenon, the *Jensen* model is widely used due to its simplicity and effectiveness, and it is adopted in this work as the basis for wake modeling. Given the complex and nonlinear nature of the wind farm *layout* optimization problem, it is necessary to employ advanced computational techniques capable of efficiently exploring the search space. In this study, three global optimization metaheuristics are evaluated: BA, GWO and MVO. The main objective is to compare the performance of these techniques in generating more efficient offshore wind farm *layouts*, using exclusively the *Jensen* model to estimate energy losses. The methodology was applied to two real offshore wind farms in the environmental licensing process by IBAMA, named Pedra Grande and Camocim, both located on the northeastern coast of Brazil. This application made it possible to analyze the specific characteristics of each farm, as well as to evaluate in detail the efficiency of the algorithms regarding solution quality, convergence and energy gain obtained after the optimization of the *layouts*. The results highlight marked differences in the behavior of the three metaheuristics. The study reinforces the importance of properly choosing the metaheuristic for the *layout* optimization problem and demonstrates that it is possible to obtain improvements in the estimation of the energy generated by the wind farm.

Keywords: Metaheuristic. Wake effect. Wind energy. Offshore wind farms. Optimization. Layout. Bat Algorithm. Grey Wolf Optimizer. Multiverse Optimizer.

LISTA DE ILUSTRAÇÕES

Figura 1	– Representação dos primeiros moinhos de vento persas.	17
Figura 2	– Galpão de la Cour.	18
Figura 3	– Crescimento do tamanho das turbinas eólicas.	20
Figura 4	– Participação das fontes na matriz elétrica Brasileira em 2023 e 2024.	21
Figura 5	– Capacidade instalada e adições renováveis 2023-2024.	22
Figura 6	– Potência Instalada de energia eólica atualmente.	23
Figura 7	– Matriz Elétrica Brasileira.	24
Figura 8	– Geração de energia eólica por região do Brasil em 2024.	25
Figura 9	– Fator de Capacidade mensal no Brasil em 2024.	25
Figura 10	– Capacidade total estimada dos investimentos nacionais <i>offshore</i>	27
Figura 11	– Distribuição geográfica de empreendimentos eólicos <i>offshore</i>	28
Figura 12	– Progresso na demanda de licenciamento.	28
Figura 13	– Parte do mapa dos projetos eólicos <i>offshore</i> no Brasil.	29
Figura 14	– Fluxograma do <i>Bat Algorithm</i>	40
Figura 15	– Fluxograma do <i>Grey Wolf Optimizer</i>	44
Figura 16	– Fluxograma do <i>Multiverse Optimization Algorithm</i>	47
Figura 17	– Parque 3x3	50
Figura 18	– Representação esquemática dos ventos norte-sul e sua interferência.	50
Figura 19	– Posição estratégia dos aerogeradores com ventos norte-sul.	51
Figura 20	– Representação esquemática dos ventos nordeste-sudoeste e sua interferência.	51
Figura 21	– Fenômeno do <i>wake effect</i>	54
Figura 22	– Rosa dos ventos do Parque Pedra Grande e do Parque Camocim	57
Figura 23	– <i>Layout</i> licenciado do Parque Pedra Grande	58
Figura 24	– Parque Pedra Grande no Programa desenvolvido.	59
Figura 25	– <i>Layout</i> otimizado pelo BA para o Parque Pedra Grande.	60
Figura 26	– <i>Layout</i> otimizado pelo MVO para o Parque Pedra Grande.	60
Figura 27	– <i>Boxplot</i> da potência - Pedra Grande.	61
Figura 28	– <i>Boxplot</i> do tempo - Pedra Grande.	62
Figura 29	– Esteira de Jensen no <i>layout</i> licenciado - Pedra Grande.	63
Figura 30	– Esteira de Jensen no <i>layout</i> otimizado pelo método MVO - Pedra Grande.	64
Figura 31	– Convergência dos algoritmos - Pedra Grande	65
Figura 32	– <i>Layout</i> licenciado do Parque Camocim.	66
Figura 33	– Parque Camocim no Programa desenvolvido.	66

Figura 34	– <i>Layout</i> otimizado pelo BA - Análise 1.	67
Figura 35	– <i>Layout</i> otimizado pelo MVO - Análise 1.	68
Figura 36	– <i>Boxplot</i> da potência - Análise 1.	69
Figura 37	– <i>Boxplot</i> do tempo - Análise 1.	70
Figura 38	– Esteira de Jensen no <i>layout</i> licenciado - Camocim.	70
Figura 39	– Esteira de Jensen no <i>layout</i> otimizado pelo método MVO - Camocim.	71
Figura 40	– Convergência dos algoritmos - Camocim.	72
Figura 41	– <i>Layout</i> otimizado pelo BA - Análise 2.	73
Figura 42	– <i>Layout</i> otimizado pelo MVO - Análise 2.	73
Figura 43	– <i>Boxplot</i> do tempo - Análise 2.	74

LISTA DE TABELAS

Tabela 1 – Síntese dos trabalhos relacionados à otimização de parques eólicos.	35
Tabela 2 – Comparação entre os algoritmos BA, GWO e MVO quanto aos mecanismos de busca.	48
Tabela 3 – Parâmetros utilizados nos algoritmos BA, GWO e MVO.	49
Tabela 4 – Ganho de Potência Média - Parque Pedra Grande.	63
Tabela 5 – Ganho de Potência Média - Parque Camocim - Análise 1.	69
Tabela 6 – Ganho de Potência Média – Parque Camocim – Análise 2.	74

LISTA DE ABREVIATURAS E SIGLAS

ABEEOLICA	Associação Brasileira de Energia Eólica
ACO	<i>Ant Colony Optimization</i>
BA	<i>Bat Algorithm</i>
EPE	Empresa de Pesquisa Energética
FC	Fator de Capacidade
FOB	Função Objetivo
GA	<i>Genetic Algorithm</i>
GE	<i>General Electric</i>
GWEC	<i>Global Wind Energy Council</i>
GWO	<i>Grey Wolf Optimizer</i>
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
IRENA	<i>International Renewable Energy Agency</i>
LPSP	<i>Loss of Power Supply Probability</i>
MFO	<i>Moth Flame Optimization</i>
MVO	<i>Multiverse Optimizer</i>
ONS	Operador Nacional do Sistema
Preólica	Programa Emergencial de Energia Eólica
Proinfa	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
PSO	<i>Particle Swarm Optimization</i>
SIN	Sistema Interligado Nacional

SUMÁRIO

1	INTRODUÇÃO	13
1.1	CONTEXTUALIZAÇÃO	13
1.2	OBJETIVOS	14
1.3	TRABALHOS PUBLICADOS	14
1.4	ESTRUTURA DO DOCUMENTO	14
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	HISTÓRIA DA ENERGIA EÓLICA	16
2.2	CENÁRIO ATUAL	20
2.2.1	Panorama Mundial e Brasileiro	20
2.2.2	Regulamentação	26
3	REVISÃO BIBLIOGRÁFICA	30
4	MÉTODOS DE OTIMIZAÇÃO	36
4.1	<i>BAT ALGORITHM</i>	37
4.2	<i>GREY WOLF OPTIMIZER</i>	41
4.3	<i>MULTIVERSE OPTIMIZATION ALGORITHM</i>	44
4.4	MECANISMOS DE BUSCA DAS METAHEURÍSTICAS	48
5	METODOLOGIA	49
5.1	PARÂMETROS ADOTADOS	49
5.2	MATRIZ INTERFERÊNCIA - REPRESENTAÇÃO DA SOLUÇÃO	49
5.3	FUNÇÃO OBJETIVO	52
5.4	<i>WAKE EFFECT</i>	53
5.5	ESTUDO DE CASOS	55
6	RESULTADOS E DISCUSSÕES	58
6.1	PARQUE PEDRA GRANDE	58
6.2	PARQUE CAMOCIM	65
6.2.1	Análise 1	67
6.2.2	Análise 2	72
6.3	DISCUSSÃO DOS RESULTADOS	75
7	CONCLUSÃO	77
	REFERÊNCIAS	79

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Com o crescimento expressivo da participação das fontes renováveis na matriz elétrica mundial e brasileira, a energia eólica se consolida como uma alternativa estratégica para diversificação energética e redução da emissão de gases de efeito estufa. Em especial, os parques eólicos *offshore* vêm ganhando destaque devido ao seu elevado potencial de geração, maior regularidade dos ventos e possibilidade de instalação de turbinas de grande porte, afastadas de áreas densamente povoadas.

Além de sua contribuição para a transição energética sustentável, a expansão da energia eólica *offshore* representa também uma oportunidade para o fortalecimento de cadeias produtivas e o avanço tecnológico no setor elétrico, promovendo inovação, qualificação profissional e geração de empregos em diversas etapas do processo, desde o planejamento até a operação das usinas.

Nesse contexto, destaca-se que os parques eólicos *onshore* enfrentam críticas quanto à poluição visual e sonora, especialmente por estarem próximos a áreas habitadas. Como alternativa, a instalação em ambiente marítimo busca mitigar esses impactos. Embora os parques *offshore* demandem maiores investimentos, devido à necessidade de estruturas específicas como cabeamento submarino e fundações resistentes ao ambiente oceânico, oferecem vantagens notáveis, como maior regularidade dos ventos e ausência de obstáculos naturais, fatores que contribuem para uma extração de potência mais eficiente e consistente.

Entretanto, apesar das vantagens, a implantação de usinas eólicas *offshore* enfrenta inúmeros desafios técnicos e operacionais. Questões como fundações subaquáticas, ancoragem, conexão com a rede elétrica por meio de cabos submarinos, e a variabilidade do ambiente marítimo exigem soluções robustas de engenharia e investimentos significativos em infraestrutura. Além disso, o correto posicionamento das turbinas no mar, conhecido como *layout*, influencia diretamente o desempenho energético e a viabilidade econômica do projeto.

A otimização do *layout* dos aerogeradores é uma etapa crítica no planejamento de parques eólicos *offshore*. Isso se deve à interação complexa entre variáveis ambientais e técnicas, como a direção dos ventos, o espaçamento entre turbinas e a turbulência gerada, além de restrições físicas e econômicas. A escolha de um modelo de otimização adequado para esse problema é fundamental para maximizar a produção de energia, minimizar perdas e garantir o melhor aproveitamento do recurso eólico disponível.

Neste contexto, diversas abordagens computacionais têm sido desenvolvidas para otimizar o *layout* de parques eólicos, variando em termos de complexidade, precisão, tempo de execução e robustez frente a diferentes cenários. A análise comparativa entre essas

abordagens pode fornecer *insights* valiosos para a seleção do modelo mais apropriado, dependendo dos objetivos e restrições de cada projeto.

1.2 OBJETIVOS

O objetivo principal deste trabalho é realizar uma análise comparativa de três diferentes modelos de otimização aplicados ao *layout* de parques eólicos *offshore*, considerando critérios como desempenho energético e eficiência computacional.

Como objetivo secundário, o estudo visa contextualizar a importância da etapa de otimização de *layout* no desenvolvimento de projetos eólicos *offshore*, com foco na realidade do setor energético, especialmente no cenário brasileiro.

1.3 TRABALHOS PUBLICADOS

As investigações relacionadas ao tema deste texto possibilitaram a publicação/aceitação dos seguintes trabalhos:

- **SOUZA, L. G. O.**; MENDONÇA, A. O.; CRUZ, T. L.; BRITO, M. E. M.; CABRAL, V. A.; JÚNIOR, I. C. S. Análise comparativa de três diferentes modelos de otimização para *layout* de parques eólicos *offshore*. In: *Simpósio Brasileiro de Pesquisa Operacional (SBPO)*, 2024, Fortaleza - CE.
- MENDONÇA, A. O.; CRUZ, T. L.; BRITO, M. E. M.; OLIVEIRA, T. C.; **SOUZA, L. G. O.**; CABRAL, V. A.; JÚNIOR, I. C. S. Impacto de diferentes modelagens de *wake effect* em parques eólicos *offshore* em licenciamento no Brasil. In: *Congresso Brasileiro de Automática (CBA)*, 2024, Rio de Janeiro - RJ.
- MENDONÇA, A. O.; CRUZ, T. L.; **SOUZA, L. G. O.**; BRITO, M. E. M.; CABRAL, V. A.; JÚNIOR, I. C. S. Simulação e análise dos impactos de diferentes modelos de *wake effect* em parques eólicos *offshore*: estudo de casos brasileiros. In: *Brazil Windpower*, 2024, São Paulo - SP.

1.4 ESTRUTURA DO DOCUMENTO

O presente trabalho está organizado em sete capítulos. Neste primeiro, uma sucinta introdução ao tema do trabalho é realizada para contextualização e definição de objetivos pretendidos.

No capítulo 2, é apresentada a fundamentação teórica do trabalho, abordando inicialmente a trajetória histórica da energia eólica, seguida por uma análise do cenário atual dessa fonte energética no Brasil e no mundo. Também são apresentadas as normas regulatórias aplicáveis ao setor.

No capítulo 3, apresenta-se a revisão bibliográfica, na qual são discutidos os principais trabalhos e pesquisas relacionados à otimização do *layout* de parques eólicos, destacando diferentes abordagens, tendências metodológicas e lacunas ainda existentes na literatura. Esse capítulo serve de base para justificar a escolha dos métodos analisados e situar o presente estudo no contexto científico atual.

No capítulo 4, são descritos detalhadamente os métodos de otimização utilizados neste trabalho. Cada metaheurística: *Bat Algorithm*, *Grey Wolf Optimizer* e *Multiverse Optimization Algorithm* é apresentada individualmente, com ênfase em seus princípios de funcionamento e características. Esse capítulo tem como objetivo fornecer o embasamento necessário para compreender o comportamento dos algoritmos nas simulações realizadas.

No capítulo 5, é exposto o problema em estudo, para a realização da otimização do *layout* dos parques eólicos. São apresentados os parâmetros utilizados em cada algoritmo, a matriz interferência, formulação da função objetivo e o modelo de *wake effect* adotado. Além disso, descrevem-se os estudos de caso selecionados.

No capítulo 6, são apresentados e discutidos os resultados das simulações realizadas para os parques eólicos Pedra Grande e Camocim. São explorados aspectos como potência gerada, variabilidade entre execuções, qualidade das soluções encontradas, tempos de processamento e comportamento dos algoritmos frente às restrições de factibilidade.

Por fim, no capítulo 7, apresentam-se as conclusões do trabalho, sintetizando os principais achados, contribuições e limitações da pesquisa. Também são indicadas possíveis extensões e recomendações para estudos futuros envolvendo a otimização de *layouts* e a aplicação de metaheurísticas em sistemas eólicos.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, são apresentados os principais fundamentos relacionados à energia eólica, incluindo um panorama histórico de sua evolução, o contexto atual dessa fonte na matriz energética mundial e brasileira, e os marcos regulatórios que orientam seu desenvolvimento.

2.1 HISTÓRIA DA ENERGIA EÓLICA

A utilização da força dos ventos acompanha a trajetória da humanidade desde tempos remotos, muito antes da invenção da eletricidade. Os primeiros registros do aproveitamento do vento remontam a aproximadamente 5.000 a.C., no Egito, onde velas eram empregadas para impulsionar embarcações no rio Nilo. De acordo com (PINTO, 2013) e (TESSMER, 2023), com o avanço das civilizações, especialmente na Mesopotâmia e na China, o vento passou a ser utilizado também para moer grãos e bombear água, representando os primeiros passos na conversão da energia eólica em trabalho mecânico.

Segundo artigo de (TESSMER, 2023) , por volta de 200 a.C., há evidências da construção de moinhos de eixo vertical na China, empregados para atividades como irrigação e moagem de grãos. No Oriente Médio, especialmente na região da Pérsia, surgiram entre os séculos VII e IX os primeiros moinhos com pás verticais parcialmente protegidas por estruturas muradas. Esses modelos, conhecidos como moinhos persas, desempenharam um papel essencial na agricultura e no abastecimento hídrico em regiões de clima árido. A Figura 1 apresenta uma pintura artística representando os primeiros moinhos de vento criado pelos persas, destacando sua engenhosidade tecnológica.

Figura 1 – Representação dos primeiros moinhos de vento persas.



Fonte: (TIMES, 2024).

De acordo com (GOMES; MARCHI, 2017), a energia eólica se expandiu significativamente na Europa durante a Idade Média, especialmente a partir do século XII, com a introdução dos moinhos de eixo horizontal. Esses modelos apresentavam maior eficiência e melhor adaptação às características dos ventos regionais. Nos Países Baixos, o uso estratégico do vento permitiu o bombeamento de água e viabilizou a drenagem de terrenos alagados, resultando na criação das chamadas polders. Esses moinhos tornaram-se marcos da engenharia local e permanecem como importantes símbolos culturais até os dias de hoje.

Com o advento da Revolução Industrial e os progressos na área da engenharia, no século XIX, surgiram as primeiras iniciativas de conversão da energia dos ventos em eletricidade. Em 1854, o inventor norte-americano Daniel Halladay registrou a patente de um moinho com múltiplas pás metálicas e sistema de autorregulação, desenvolvido principalmente para o bombeamento de água. Considerado o primeiro moinho de vento comercial, esse equipamento se espalhou rapidamente pelas zonas rurais dos Estados Unidos, desempenhando papel fundamental no abastecimento de locomotivas a vapor e em outras demandas do meio agrícola (PINTO, 2013).

O marco inicial da produção de eletricidade por meio da energia eólica ocorreu

em 1887, quando o engenheiro escocês James Blyth construiu um gerador eólico capaz de alimentar a iluminação de sua própria residência (HENRY, 2018). No ano seguinte, o inventor norte-americano Charles F. Brush desenvolveu uma turbina de madeira com impressionantes 17 metros de diâmetro e 144 pás. Essa turbina era conectada a um dínamo com potência de cerca de 12 kW de energia, quantidade suficiente para fornecer eletricidade à sua casa e oficina durante mais de duas décadas.

Nesse mesmo período, destacou-se também o dinamarquês Poul la Cour (1846–1908), cuja contribuição foi fundamental para o aprimoramento do design das turbinas eólicas. Ele reduziu o número de pás e introduziu técnicas aerodinâmicas mais eficientes, o que resultou em equipamentos mais funcionais. Como resultado de suas pesquisas, mais de 70 turbinas já estavam instaladas na Dinamarca em 1909 para a geração de eletricidade em corrente contínua. Sua importância histórica é reconhecida até os dias atuais, com um museu dedicado à sua memória, onde estão preservadas suas descobertas e experimentos. A Figura 2 apresenta um dos trabalhos de la Cour.

Figura 2 – Galpão de la Cour.



Fonte: (Poul la Cour Museet, 2025)

O crescimento do uso da energia eólica na Dinamarca foi progressivo. Em 1909 já existiam 72 turbinas em operação, número que subiu para 120 em 1918. Em 1957, um dos primeiros alunos de la Cour, o engenheiro Johannes Juul, desenvolveu uma turbina de três pás dotada de estol aerodinâmico para controle de potência, além de incorporar um gerador de indução e um gerador síncrono. Essa turbina, com rotor de 24 metros de

diâmetro e potência de 200 kV, foi a primeira do mundo a operar com corrente alternada (PINTO, 2013).

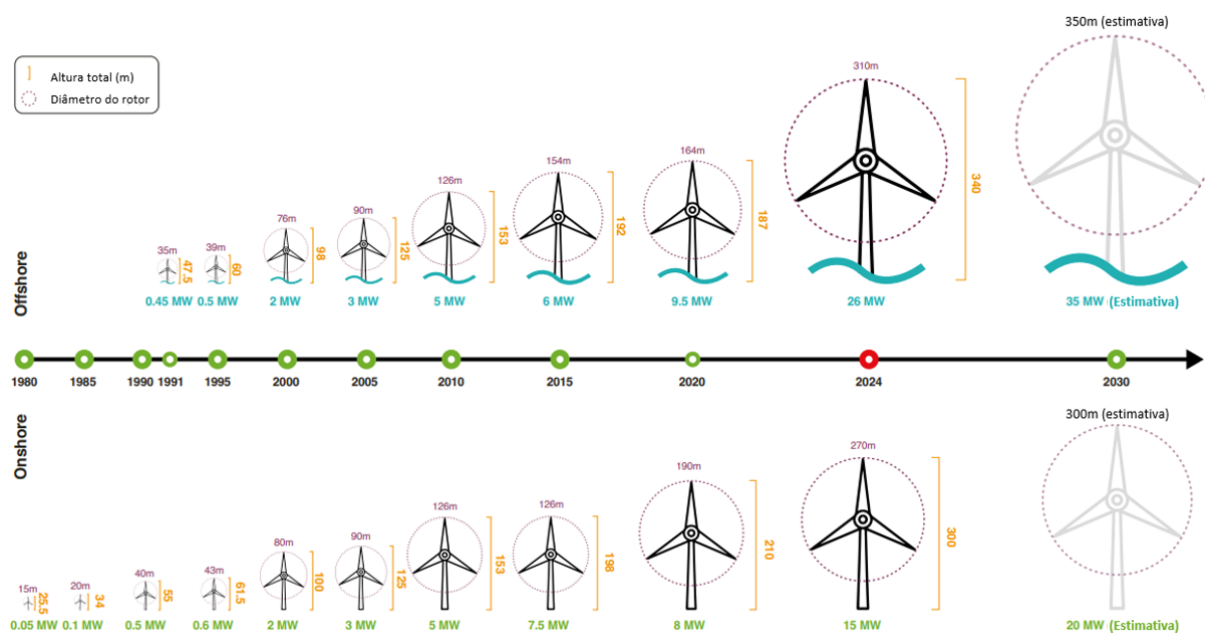
Ainda na primeira metade do século XX, o engenheiro alemão Hermann Honnef foi pioneiro ao propor, na década de 1930, a ideia da geração eólica em larga escala, incluindo instalações *offshore*. Entre suas contribuições, destaca-se um modelo com três rotores, desenvolvido com o objetivo de ampliar a participação da energia eólica na matriz energética. Na mesma época, foi idealizado um projeto de usina eólica *offshore*, datado de 1932, que, no entanto, nunca chegou a ser construído.

Com o aumento da demanda global por eletricidade, a engenharia eólica passou a concentrar esforços no desenvolvimento de turbinas de maior porte e eficiência. Em 1941, os Estados Unidos construíram a turbina Smith-Putnam, no estado de Vermont, com capacidade de 1,25 MW, o que representou um marco tecnológico para a época. No entanto, o projeto foi descontinuado pouco tempo depois, devido a falhas estruturais identificadas durante a operação e à baixa competitividade econômica frente aos combustíveis fósseis, cujos custos permaneceram reduzidos no período pós-Segunda Guerra Mundial.

O interesse pela energia eólica voltou a crescer nas décadas de 1970 e 1980, impulsionado pelas crises do petróleo e pela busca por fontes renováveis de energia. A Dinamarca, mais uma vez, destacou-se nesse contexto ao adotar um modelo de desenvolvimento baseado em cooperativas locais, com forte incentivo à produção nacional de turbinas. Nesse cenário, a turbina Gedser, projetada por Johannes Juul em 1957, tornou-se uma referência para os aerogeradores modernos, por apresentar três pás e controle automático por estol aerodinâmico.

A transição para projetos de grande escala ocorreu no final do século XX e início do século XXI, com destaque para os primeiros parques eólicos *offshore*. O pioneiro foi o parque Vindeby, inaugurado na Dinamarca em 1991. Desde então, o crescimento no tamanho e na potência das turbinas tem sido exponencial. Enquanto os modelos da década de 1980 possuíam rotores com cerca de 20 metros de diâmetro e potências inferiores a 100 kW, em 2010 foi desenvolvida a turbina Haliade, com 153 metros de diâmetro. Mais recentemente, a China lançou a turbina GWH252-16MW, com mais de 250 metros de diâmetro e capacidade de 25 MW (VAICBERG; VALIATT; FERREIRA, 2021). As turbinas *offshore* utilizadas têm sido aprimoradas constantemente, assim como o conhecimento sobre as condições de operação no mar. A Figura 3 apresenta a evolução do diâmetro e potência das turbinas instaladas em parques eólicos *offshore*.

Figura 3 – Crescimento do tamanho das turbinas eólicas.



Fonte: Adaptado de (GWEC, 2025)

Com o avanço das tecnologias, tornou-se viável a construção de aerogeradores cada vez maiores, capazes de gerar volumes expressivos de energia. De acordo com (GWEC, 2025), em 2023, a energia eólica já figurava entre as fontes que mais crescem no setor elétrico mundial, com destaque para a China e os Estados Unidos, líderes em capacidade instalada e inovação tecnológica.

No Brasil, a primeira experiência com geração eólica remonta à década de 1990, na ilha de Fernando de Noronha, onde foi instalada uma turbina de 75 kW. A partir de 2001, a criação do Programa Emergencial de Energia Eólica (Preólica), seguida pelo Programa de Incentivo às Fontes Alternativas de Energia Elétrica (Proinfa), impulsionou de forma decisiva o desenvolvimento do setor. Atualmente, o país figura entre os dez maiores produtores de energia eólica do mundo, com destaque para os parques localizados na região Nordeste, onde os ventos constantes e intensos oferecem condições ideais para esse tipo de geração (CABRAL, 2015).


2.2 CENÁRIO ATUAL

2.2.1 Panorama Mundial e Brasileiro

Nas últimas décadas, a matriz energética global tem passado por uma transição significativa, motivada pela urgência de reduzir as emissões de gases de efeito estufa e assegurar a segurança energética frente às mudanças climáticas. Nesse cenário, a energia eólica destaca-se como uma das fontes renováveis mais promissoras, graças à sua

competitividade econômica, baixo impacto ambiental e ampla disponibilidade geográfica. No Brasil, essa tendência também se reflete na composição da matriz elétrica nacional, conforme ilustrado na Figura 4, que compara a participação das diferentes fontes de geração entre os anos de 2023 e 2024. Observa-se uma redução na contribuição da fonte hidráulica, que historicamente tem sido predominante no país, passando de 58,9% para 55,3%. Essa queda foi compensada, principalmente, pelo crescimento das fontes solar fotovoltaica, que passou de 7,0% para 9,3%, e eólica, que subiu de 13,2% para 14,1%, além do aumento do uso de gás natural, de 6,3% para 7,0%. Essas mudanças evidenciam a diversificação da matriz elétrica brasileira, com destaque para o avanço das fontes renováveis não convencionais, como a eólica e a solar. A figura também mostra que a oferta total de eletricidade aumentou 5,5% em relação a 2023, mesmo com uma queda de 1,7% na oferta hídrica, reforçando o papel das demais fontes na garantia do suprimento energético.

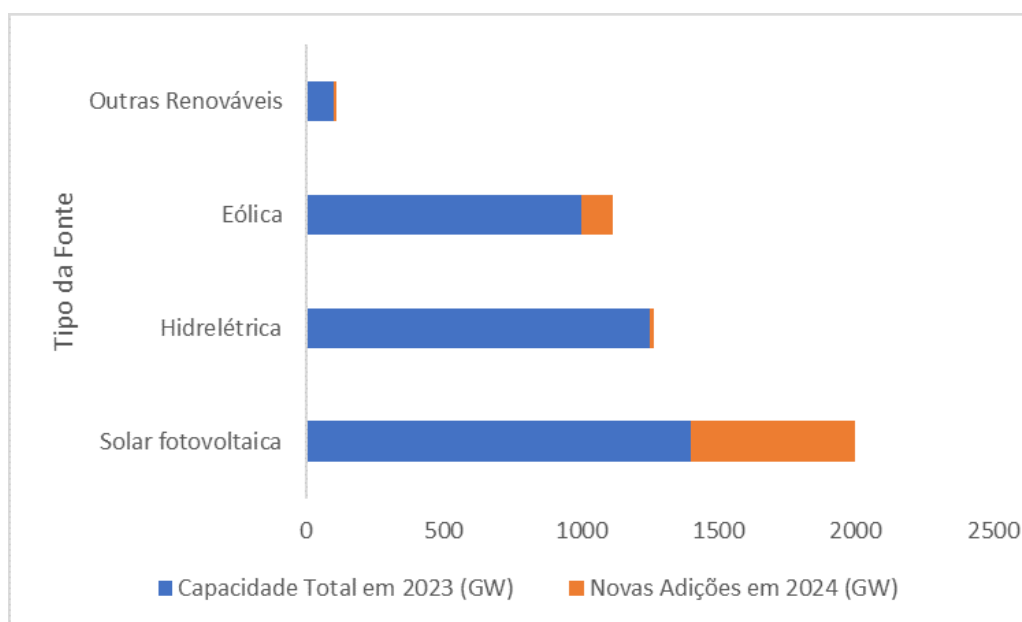
Figura 4 – Participação das fontes na matriz elétrica Brasileira em 2023 e 2024.



Fonte: Adaptado da Empresa de Pesquisa Energética (EPE, 2025).

De acordo com o Global Wind Report 2025, publicado pelo *Global Wind Energy Council* (GWEC) (GWEC, 2025), a capacidade total instalada de energia eólica no mundo atingiu aproximadamente 1.145 GW até o final de 2024, somando os sistemas *onshore* (em terra) e *offshore* (no mar). Desse total, 83,2 GW referem-se à capacidade *offshore*, representando cerca de 7,3% da capacidade global, evidenciando a crescente relevância dessa tecnologia no cenário internacional (GWEC, 2025), conforme ilustrado na Figura 5.

Figura 5 – Capacidade instalada e adições renováveis 2023-2024.



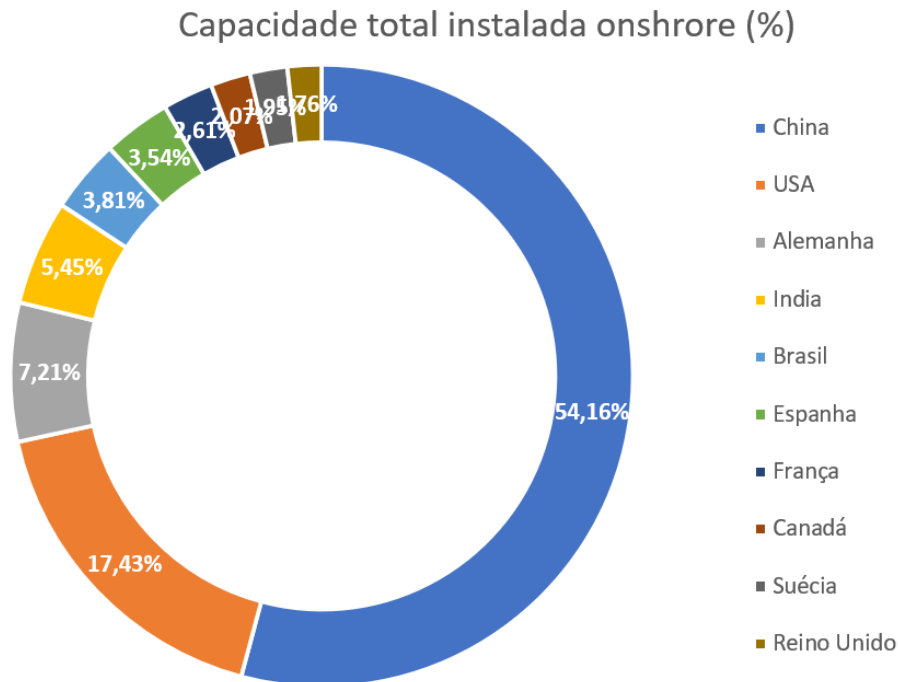
Fonte: Elaborado pela autora a partir de (GWEC, 2025).

A China mantém-se como líder mundial em energia eólica, ocupando o primeiro lugar no segmento *offshore* pelo sétimo ano consecutivo, com cerca de 50% da capacidade global instalada nesse segmento. O ranking também inclui Reino Unido, Alemanha, Holanda e Taiwan. A Dinamarca, embora pioneira na área, deixou de figurar entre os cinco maiores mercados em 2024. Apesar da leve desaceleração nas novas conexões *offshore*, que totalizaram 8 GW em 2024, representando uma queda de 26% em relação a 2023, o setor ainda registrou seu quarto melhor desempenho anual em expansão (GWEC, 2025).

As perspectivas para a próxima década são otimistas: estima-se que, até 2034, sejam adicionados 350 GW de capacidade *offshore*, alcançando um total acumulado de 441 GW, o que representaria uma ampliação significativa da participação da energia eólica no mix energético mundial. Espera-se que a energia eólica *offshore* represente, até 2034, cerca de 25% das novas instalações anuais, com destaque para mercados emergentes na América Latina, África e região Ásia-Pacífico, onde o potencial técnico ainda é subexplorado.

No Brasil, a energia eólica consolidou-se como uma das principais fontes da matriz elétrica, destacando-se por seu crescimento acelerado e pelo potencial de expansão. Atualmente, o país ocupa a 5ª posição mundial em capacidade instalada *onshore*, com mais de 30 GW em operação, de acordo com o GWEC (GWEC, 2025). A Figura 6 ilustra a distribuição percentual da capacidade eólica instalada *onshore* no mundo, evidenciando a liderança da China (54,16%), seguida pelos Estados Unidos (17,43%) e Alemanha (7,21%). O Brasil aparece com 3,81% da capacidade global, consolidando-se como um dos principais mercados emergentes no setor.

Figura 6 – Potência Instalada de energia eólica atualmente.



Fonte: Elaborado pela autora a partir de (GWEC, 2025).

Esse crescimento expressivo resulta da combinação de políticas públicas de incentivo, realização de leilões de energia e características naturais favoráveis, como a extensa costa litorânea e a predominância de ventos constantes e intensos, especialmente nas regiões Nordeste e Sul. Segundo Empresa de Pesquisa Energética (EPE), o Brasil possui um potencial técnico superior a 1.000 GW para geração eólica, sendo mais de 700 GW apenas *offshore*, com destaque para os estados do Ceará, Rio Grande do Norte e Maranhão (EPE, 2025).

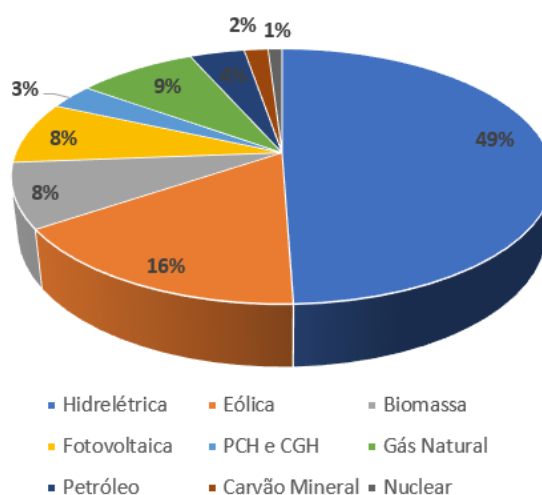
Embora ainda não existam usinas eólicas *offshore* em operação no país, o cenário vem se transformando rapidamente. De acordo com o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), mais de 80 projetos estão em fase de licenciamento, totalizando uma potência proposta superior a 200 GW (IBAMA, 2025).

Segundo o Operador Nacional do Sistema (ONS), em maio de 2024, a capacidade total instalada no Sistema Interligado Nacional (SIN) era de 221.621 MW, dos quais aproximadamente 13% correspondem à geração eólica. A projeção é que esse valor alcance 254.431 MW até 2028, com destaque para a expansão das fontes renováveis (ONS, 2025).

A matriz elétrica brasileira é composta predominantemente por um sistema hidro-termo-eólico de grande porte, devido à elevada geração proveniente dessas três principais fontes de energia. Como ilustrado na Figura 7, observa-se a diversidade das fontes que compõem a matriz elétrica ao final de 2024. Considerando todas as fontes de geração

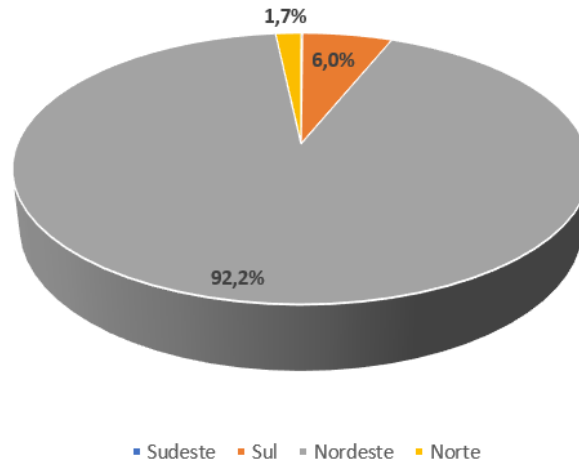
elétrica, em 2024 foram instalados 3,3 GW de nova potência, sendo a energia eólica a segunda fonte que mais cresceu no ano, representando 10,8% da nova capacidade instalada. Esse crescimento fez com que a fonte eólica atingisse 16,1% de participação na matriz elétrica brasileira, consolidando-se como uma das principais fontes renováveis do país. Esse avanço é fortemente impulsionado pela região Nordeste, responsável por mais de 90% da produção eólica nacional. A predominância dessa região se deve à abundância de ventos favoráveis, com características constantes e de alta intensidade, além de uma topografia ideal para instalação dos aerogeradores. Os estados do Rio Grande do Norte, Bahia, Ceará e Piauí lideram o ranking nacional, tanto em potência instalada quanto em energia efetivamente gerada, de acordo com a Associação Brasileira de Energia Eólica (ABEEOLICA) (ABEEÓLICA, 2025). A Figura 8 ilustra essa concentração regional, evidenciando a expressiva participação do Nordeste na geração de energia eólica em 2024.

Figura 7 – Matriz Elétrica Brasileira.



Fonte: Elaborado pela autora a partir de (ABEEÓLICA, 2025).


Figura 8 – Geração de energia eólica por região do Brasil em 2024.



Fonte: Elaborado pela autora a partir de (ABEEÓLICA, 2025).

O Fator de Capacidade (FC) de uma usina representa a razão entre a sua produção efetiva e a capacidade total instalada em um mesmo período. Esse indicador é fundamental para avaliar o desempenho de empreendimentos de geração elétrica e pode variar significativamente entre países, sendo influenciado por fatores como a localização geográfica das usinas, a qualidade do recurso eólico e as tecnologias utilizadas. O Brasil tem se destacado mundialmente nesse quesito. Em 2021, o fator de capacidade médio das usinas eólicas brasileiras foi de 52%, superando com folga a média global de 39%, conforme dados da *International Renewable Energy Agency* (IRENA) (IRENA, 2018). Trata-se de um desempenho notável, considerando que o FC típico para a fonte eólica costuma variar entre 20% e 40%. Além disso, dados do ONS apontam que estados como Bahia, Rio Grande do Norte e Ceará alcançaram, entre 2021 e 2023, índices superiores a 55%, o que reforça a viabilidade técnica e econômica da expansão eólica no Brasil. Já em 2024, de acordo com a Associação Brasileira de Energia Eólica (ABEEÓLICA, 2025), o FC médio nacional foi de 38%. O desempenho variou ao longo dos meses, atingindo seu pico em setembro, com 50%, conforme mostrado na Figura 9.

Figura 9 – Fator de Capacidade mensal no Brasil em 2024.



Fonte: (ABEEÓLICA, 2025).

2.2.2 Regulamentação

A regulamentação da geração de energia eólica *offshore* no Brasil avançou significativamente com a aprovação do Projeto de Lei nº 11247/2018, em 29 de novembro de 2023. Essa nova legislação estabelece dois modelos distintos para a disponibilização de áreas marítimas destinadas à exploração energética: a oferta permanente e a oferta planejada. Na oferta permanente, as áreas podem ser pleiteadas diretamente por agentes interessados, sendo a análise e autorização responsabilidade do poder concedente. Já na oferta planejada, o governo define previamente os blocos e realiza leilões para a concessão (FERREIRA, 2023).

Dentre os principais aspectos discutidos durante a tramitação do projeto está a compensação financeira pelo uso do espaço marítimo público, comumente conhecida como pagamento de royalties. A proposta inicial previa uma alíquota de 5% sobre a energia gerada, conforme delineado no Projeto de Lei nº 576/2021. Contudo, ao longo do processo legislativo, esse percentual foi reduzido para 1,5%. É relevante observar que o texto final aprovado pela Câmara dos Deputados não estipula um valor mínimo obrigatório para a cobrança desses royalties, o que pode impactar diretamente a previsibilidade regulatória e os incentivos para o setor (FERREIRA, 2023).

Outro ponto abordado pela nova legislação refere-se à necessidade de fomento à indústria nacional. Ainda que o texto mencione a importância do incentivo à produção local, não define diretrizes claras ou metas específicas que assegurem esse desenvolvimento. A ausência de instrumentos regulatórios concretos evidencia a urgência de políticas públicas complementares que estimulem inovação tecnológica, geração de empregos qualificados e o fortalecimento da cadeia produtiva nacional no segmento eólico *offshore* (FERREIRA, 2023).

A construção de um arcabouço regulatório mais robusto e detalhado é, portanto, fundamental para consolidar a posição do Brasil como um dos líderes emergentes na geração de energia *offshore*. Estudos anteriores sugerem que, para isso, é crucial desenvolver modelos de leilão específicos para esse tipo de projeto, os quais devem considerar não apenas o menor preço ofertado, mas também atributos qualitativos como a inclusão de cláusulas que promovam a pesquisa, inovação e integração com a indústria nacional (CABRAL, 2015).

Paralelamente ao avanço normativo, o desenvolvimento técnico e o interesse comercial pela energia eólica *offshore* no Brasil têm crescido de forma expressiva. Dados ONS indicam que estados como Maranhão, Piauí e Bahia apresentaram elevados fatores de capacidade média no período entre 2021 e 2023, revelando um cenário promissor para o aproveitamento dos recursos eólicos marítimos.

Até julho de 2025, o IBAMA já havia recebido 104 pedidos de licenciamento ambiental para projetos eólicos *offshore*, distribuídos por oito estados do litoral brasileiro. A capacidade total estimada desses projetos atinge 247,3 GW, conforme apresentado na

Figura 10, um volume que demonstra o interesse crescente de investidores nacionais e internacionais nesse mercado estratégico (IBAMA, 2025). A distribuição geográfica desses empreendimentos, bem como a evolução temporal das solicitações, estão representadas nas Figuras 11 e 12, respectivamente (IBAMA, 2025).

Figura 10 – Capacidade total estimada dos investimentos nacionais *offshore*.




Fonte: (IBAMA, 2025).

Figura 11 – Distribuição geográfica de empreendimentos eólicos *offshore*.



Fonte: (IBAMA, 2025).

Figura 12 – Progresso na demanda de licenciamento.



Fonte: (IBAMA, 2025).

Apesar desse dinamismo, o setor enfrenta um dos seus principais desafios: a sobreposição de áreas entre diferentes projetos. Muitos empreendimentos têm sido propostos para as mesmas regiões marítimas, gerando conflitos de uso e exigindo critérios mais refinados de ordenamento espacial. A Figura 13 ilustra essa problemática ao mostrar as áreas marítimas sob análise e a coincidência entre os pedidos (IBAMA, 2025).

Figura 13 – Parte do mapa dos projetos eólicos *offshore* no Brasil.



Fonte: (IBAMA, 2025).

O relatório do IBAMA também oferece um panorama técnico detalhado sobre os projetos em avaliação, incluindo informações como os nomes dos empreendedores, tipos e modelos de aerogeradores, quantidade e potência instalada. Dentre os modelos mais recorrentes estão o V236 de 15 MW da Vestas, presente em 36% dos projetos; o Haliade-X de 12 MW da *General Electric* (GE), com 8%; e o WEC 265 de 20 MW, que aparece em 7% dos casos. Juntos, esses três modelos somam mais de 73% das propostas com aerogeradores já definidos.

Outro aspecto relevante é a diversificação dos agentes empreendedores no setor eólico *offshore* brasileiro. Dos 104 projetos protocolados, cerca de 24% pertencem a empresas com apenas um único projeto cadastrado, enquanto o restante é de companhias que atuam com múltiplos empreendimentos em diferentes regiões do país. Essa configuração revela não apenas o aumento da competitividade no setor, mas também um elevado grau de internacionalização, com a presença de grandes players como Petrobras, TotalEnergies e Shell, além da distribuição geográfica variada dos empreendedores, o que reforça o interesse por diversas áreas do litoral nacional (IBAMA, 2025).

3 REVISÃO BIBLIOGRÁFICA

Este capítulo tem como objetivo apresentar e discutir estudos relevantes relacionados ao tema desta pesquisa, destacando os métodos empregados, os modelos adotados e os principais objetivos de cada investigação.

(CABRAL, 2021), desenvolveu um estudo voltado à otimização do *layout* e do sistema coletor de parques eólicos *offshore*, empregando o algoritmo de ecolocalização de morcegos *Bat Algorithm* (BA) em sua versão adaptada. O trabalho teve como principal objetivo aprimorar a eficiência na alocação das turbinas e na configuração do sistema de cabos, de modo a maximizar a extração de energia e minimizar as perdas elétricas e os custos associados.

O autor apresentou uma formulação matemática detalhada do *wake effect*, considerando a redução da velocidade do vento causada pela interferência entre aerogeradores, e modelou o problema de forma discreta, com a área do parque dividida em células retangulares representando possíveis posições de instalação. Foram avaliadas diferentes técnicas de otimização baseadas em inteligência computacional, incluindo o *Grey Wolf Optimizer* (GWO), o *Particle Swarm Optimization* (PSO) e as versões original e modificada do algoritmo BA (BAT modificado), visando analisar o desempenho e a eficiência computacional de cada abordagem.

Os resultados obtidos em simulações de casos tutoriais e em um estudo de caso aplicado ao litoral do Nordeste brasileiro demonstraram que o algoritmo BAT-mod apresentou desempenho superior em relação às demais técnicas, tanto na definição do *layout* das turbinas quanto na otimização do sistema coletor. As modificações introduzidas no algoritmo de ecolocalização resultaram em melhor convergência e maior eficiência na busca de soluções, proporcionando uma redução de 10,66% nas perdas de geração associadas ao *wake effect*, além de configurações mais econômicas em termos de cabeamento e perdas elétricas. O estudo evidenciou, portanto, o potencial de aplicação de métodos bioinspirados na otimização integrada de parques eólicos *offshore*, contribuindo para o avanço das técnicas de modelagem e planejamento desse tipo de empreendimento.

(AMOUSSOU *et al.*, 2023) propôs um modelo de otimização para dimensionamento ótimo de um sistema híbrido de geração de energia composto por fontes fotovoltaicas, eólicas e sistemas de armazenamento baseados em hidrogênio e baterias de íon-lítio. O estudo teve como objetivo substituir uma usina termoelétrica a óleo combustível pesado (HFO) localizada no sudoeste de Camarões, buscando reduzir o custo total do projeto ao longo de sua vida útil, mantendo níveis aceitáveis de confiabilidade energética, medidos pelo índice *Loss of Power Supply Probability* (LPSP).

O trabalho é relevante por integrar critérios técnicos e econômicos em um único problema de otimização e por aplicar quatro metaheurísticas distintas para a obtenção

da solução ótima: *Moth Flame Optimization* (MFO), *Improved Grey Wolf Optimizer* (IGWO), *Multiverse Optimizer* (MVO) e *African Vultures Optimization Algorithm* (AVOA). A adoção de múltiplos algoritmos teve como propósito assegurar a robustez dos resultados, possibilitando uma comparação direta entre as técnicas em termos de custo total do ciclo de vida (TLCC), velocidade de convergência e qualidade das soluções obtidas.

Entre os algoritmos utilizados, o MFO apresentou melhor desempenho, alcançando o menor custo total do projeto (US\$ 692.291.975,22) e a convergência mais rápida, atingindo o ótimo após 105 iterações. As demais técnicas, embora tenham produzido resultados próximos, apresentaram custos ligeiramente superiores (diferenças entre 0,32% e 0,63%), o que evidencia a consistência dos resultados e a efetividade do MFO para o tipo de problema abordado. Esse resultado reforça o potencial do MFO em problemas de dimensionamento de sistemas híbridos renováveis, caracterizados por alta não linearidade e múltiplas restrições.

(SHIN; BAEK; RHEE, 2020) investigou a otimização do arranjo de turbinas em parques eólicos *offshore*, com foco na maximização da produção anual de energia (AEP) e na minimização das perdas por *wake effect*. O estudo é relevante no contexto de energia renovável, especialmente para regiões como a Coreia do Sul, onde os parques *offshore* enfrentam limitações geográficas e ambientais, como proximidade da costa e relevo complexo.

O artigo apresenta um estudo de caso de um parque eólico de 60 MW na costa de Busan, utilizando dados de vento entre 2001 e 2018 para análise do recurso eólico local. Os autores aplicaram algoritmos evolutivos (EA) e de *Particle Swarm Optimization* (PSO) para otimizar a disposição das turbinas, comparando dois cenários: um baseado em padrões regulares de linhas e colunas, e outro utilizando coordenadas livres para cada turbina. Para ambos os cenários, foi utilizado um metamodelo que aproximava funções computacionalmente intensivas, permitindo que os algoritmos de otimização funcionassem de forma eficiente sem perda de confiabilidade.

Os resultados mostraram que, com o *layout* otimizado, a produção anual de energia atingiu 172.437 MWh, com fator de capacidade de 26,5%, o que poderia suprir cerca de 4,6% do consumo de eletricidade da região metropolitana de Busan em 2019. Entre as variáveis de projeto mais influentes, destacam-se o ângulo de rotação das turbinas em relação à direção predominante do vento e a distância em relação à costa, sendo que o aumento da distância da costa aumentou a AEP, mas não reduziu linearmente as perdas por esteira, que se tornaram mínimas a 1.250 m da costa.

O artigo de (RAMLI; BOUCHEKARA, 2020) apresenta uma proposta de otimização para o problema de *layout* de parques eólicos (*Wind Farm Layout Optimization – WFLO*) por meio de uma nova metaheurística denominada *Binary Most Valuable Player Algorithm* (BMVPA). O objetivo do estudo é posicionar de forma eficiente as turbinas eólicas dentro de uma área pré-definida, considerando restrições espaciais, efeitos de *wake effect*, curva de

potência e diferentes cenários de vento, a fim de minimizar o custo de energia e maximizar o aproveitamento do recurso eólico.

O problema de WFLO é reconhecido por sua natureza não linear, multimodal e de alta dimensionalidade, o que o torna difícil de resolver por métodos de otimização clássicos. Por esse motivo, o artigo propõe a utilização de uma metaheurística moderna baseada em uma metáfora esportiva. O algoritmo original MPVA, foi desenvolvido para espaços de busca contínuos e modela a competição entre “jogadores”, que representam soluções potenciais, organizados em “times”. Cada iteração do processo envolve fases de competição individual e coletiva, nas quais os jogadores atualizam suas habilidades com base no desempenho do melhor jogador do time (*franchise player*) e do melhor jogador da liga (MVP).

Como o problema de *layout* eólico envolve decisões binárias, a presença (1) ou ausência (0) de turbinas em cada ponto do terreno, os autores desenvolveram uma versão binária do MVPA, denominada BMVPA. Essa adaptação utiliza uma função de transferência hiperbólica, que converte as atualizações contínuas em probabilidades de troca entre os estados binários. Assim, o algoritmo mantém o comportamento adaptativo do MVPA, mas adequado a problemas discretos.

A metodologia foi aplicada em dez cenários distintos, que consideraram diferentes tamanhos de terreno, velocidades de vento e situações com e sem obstáculos. O desempenho do BMVPA foi comparado com o de duas outras metaheurísticas amplamente utilizadas: Binary Particle Swarm Optimization (BPSO) e *Genetic Algorithm* (GA), a fim de avaliar sua eficiência e robustez.

Os resultados mostraram que o BMVPA apresentou desempenho superior em nove dos dez cenários testados, alcançando menores custos de energia e maior estabilidade das soluções em comparação com os demais algoritmos. Apenas no cenário 9 o BPSO obteve resultados ligeiramente melhores. Verificou-se também que a introdução de obstáculos nos terrenos elevou o custo de energia, uma vez que reduziu o espaço de busca e limitou o número de configurações possíveis. Ainda assim, o BMVPA manteve resultados consistentes, demonstrando boa robustez e capacidade de convergência.

Além disso, os autores destacaram que o algoritmo apresentou menores perdas por *wake effect* em relação às demais técnicas, contribuindo para um arranjo mais eficiente das turbinas. A análise detalhada dos cenários reforçou a vantagem do BMVPA tanto em terrenos livres quanto em terrenos com restrições espaciais.

O artigo enfatiza que o BMVPA se mostra uma alternativa promissora para a otimização de *layouts* de parques eólicos, aliando simplicidade conceitual, eficiência e flexibilidade para tratar variáveis discretas.

O artigo de (AMARAL; CASTRO, 2017), apresenta uma metodologia voltada à otimização do *layout* de parques eólicos *offshore*, considerando simultaneamente as perdas

associadas ao *wake effect* e às perdas elétricas internas da rede de coleta. Diante dos elevados custos envolvidos na geração *offshore*, o estudo busca maximizar a produção anual de energia (AEP) e, conseqüentemente, reduzir o custo nivelado de energia (LCOE). Para isso, os autores propõem o posicionamento estratégico das turbinas dentro de uma malha de subcélulas retangulares, o que permite maior flexibilidade no arranjo espacial das máquinas. O problema de otimização é resolvido por meio de algoritmos metaheurísticos, especificamente o GA e o PSO, os quais são comparados quanto à eficiência computacional e à capacidade de encontrar configurações de máxima produção. Os resultados evidenciam que o método metaheurístico, em especial o GA, é mais eficaz na determinação do arranjo ótimo, oferecendo um equilíbrio entre a minimização das perdas por esteira e das perdas elétricas internas. O estudo contribui para o avanço das técnicas de otimização aplicadas ao planejamento de parques eólicos *offshore*, reforçando a importância de abordagens integradas que considerem simultaneamente fatores aerodinâmicos e elétricos.

O estudo de (PILLAI *et al.*, 2017) propõe uma metodologia sistemática para a otimização do *layout* de parques eólicos *offshore*, aplicando-a ao caso do parque eólico Middelgrunden, localizado próximo a Copenhague, Dinamarca. O principal objetivo do trabalho é desenvolver e validar uma estrutura de otimização capaz de reduzir o Custo Nivelado de Energia (LCOE), considerando de forma integrada os aspectos energéticos e econômicos do projeto.

A metodologia incorpora uma modelagem detalhada do LCOE, superando limitações de ferramentas anteriores que tratavam os custos de maneira simplificada. O modelo abrange os componentes de custos de capital (CAPEX) e custos operacionais (OPEX), além da produção anual de energia (AEP). Para a etapa de otimização, foram empregados dois algoritmos de inteligência artificial, sendo eles o Algoritmo Genético (GA) e o *Particle Swarm Optimization* (PSO), sob três diferentes conjuntos de restrições: modo contínuo, modo em grade (array) e modo binário, variando conforme o nível de liberdade posicional das turbinas.

Os resultados indicaram que ambos os métodos apresentaram reduções no LCOE entre 1% e 3,5% em relação ao *layout* original do Middelgrunden, com aumento na AEP e incrementos moderados no custo total. Essas reduções corresponderam a ganhos no Valor Presente Líquido (NPV) entre 1,5 e 4,7 milhões de euros, demonstrando o potencial econômico de pequenas melhorias na disposição das turbinas. O estudo também revelou que, embora o GA e o PSO apresentem desempenho semelhante, o conjunto de restrições espaciais exerce maior influência sobre o resultado final do que o tipo de algoritmo utilizado.

Apesar da alta precisão na estimativa da produção de energia (erro inferior a 1%), a modelagem de custos apresentou maior incerteza, especialmente no termo OPEX (erro superior a 200%), atribuída ao uso de dados históricos de anos com baixa despesa operacional e às particularidades do Middelgrunden, conhecido por seus custos abaixo

da média da indústria. Ainda assim, os autores destacam que tais erros são sistemáticos entre os diferentes *layouts*, não comprometendo a validade da metodologia na etapa de otimização.

Além de evidenciar o impacto de fatores técnicos e econômicos, o estudo discute também aspectos sociais e regulatórios, como as restrições de impacto visual que influenciaram o projeto real, ressaltando que limitações dessa natureza podem reduzir a eficiência econômica de um parque. A comparação entre o *layout* otimizado e o *layout* construído permitiu quantificar essas perdas e demonstrar o valor da abordagem proposta como ferramenta de apoio à decisão para planejadores e desenvolvedores de projetos *offshore*.

Em continuidade a essa pesquisa, (TEGNER *et al.*, 2018) expandem a metodologia de (PILLAI *et al.*, 2017) ao propor um modelo abrangente de otimização de *layout* fundamentado em uma função de custo nivelado de energia (LCOE) mais detalhada, que considera simultaneamente aspectos de geração e custos ao longo de toda a vida útil do empreendimento. A abordagem busca representar de forma mais realista as interações entre desempenho energético e custos de investimento e operação, estruturando-se desde a definição das posições das turbinas até a otimização da infraestrutura elétrica intra-array, isto é, das conexões internas entre as turbinas.

O modelo introduz três modos de operação: array mode, baseado em uma malha regular de espaçamento constante; binary mode, no qual o espaço do parque é discretizado em posições permitidas; e continuous mode, que admite liberdade total de posicionamento dentro da área do parque. Essa flexibilidade permite avaliar o impacto de restrições regulatórias, como as impostas por órgãos marítimos, sobre o desempenho e o custo global do projeto.

Além disso, (TEGNER *et al.*, 2018) incorporam um submódulo de otimização elétrica, que utiliza algoritmos de busca de caminhos e programação linear inteira mista (MILP) para determinar as rotas e dimensões ótimas dos cabos submarinos, considerando obstáculos do leito marinho e limitações de capacidade. Dessa forma, o modelo integra a análise do *layout* físico ao dimensionamento técnico e econômico da infraestrutura elétrica, aspecto frequentemente simplificado em estudos anteriores.

Na etapa de otimização, os autores empregam novamente os algoritmos GA e PSO, configurados com parâmetros adaptativos para garantir convergência e evitar soluções locais. Aplicado ao parque de Middelgrunden, o modelo manteve alta precisão na estimativa da AEP (erro inferior a 1%) e indicou reduções potenciais de 1% a 3,5% no LCOE, equivalentes a ganhos financeiros entre 1,5 e 4,7 milhões de euros ao longo da vida útil do projeto.

A Tabela 1 apresenta uma síntese dos principais trabalhos relacionados à otimização de parques eólicos. Observa-se que diferentes metaheurísticas têm sido aplicadas para resolver problemas de otimização de layout e dimensionamento de sistemas energéticos, como GA, PSO, GWO, MFO e outras abordagens bioinspiradas. Entretanto, ainda existem

desafios relacionados à comparação entre diferentes algoritmos e à análise do desempenho dessas técnicas em cenários específicos de parques eólicos offshore.

Tabela 1– Síntese dos trabalhos relacionados à otimização de parques eólicos.

Referência	Problema abordado	Método de otimização	Aplicação	Principais resultados
(AMARAL; CASTRO, 2017)	Otimização considerando wake effect e perdas elétricas	GA e PSO	Parques eólicos offshore	GA apresentou melhor equilíbrio entre produção energética e perdas elétricas.
(PILLAI <i>et al.</i> , 2017)	Otimização visando redução do LCOE	GA e PSO	Parque Middelgrunden (Dinamarca)	Redução entre 1% e 3,5% no LCOE.
(TEGNER <i>et al.</i> , 2018)	Otimização integrada de layout e rede elétrica	GA, PSO e MILP	Parque Middelgrunden	Integração entre layout das turbinas e infraestrutura elétrica do parque.
(RAMLI; BOUCHEKARA, 2020)	Problema WFLO com restrições espaciais	BMVPA, BPSO e GA	Posicionamento de turbinas em diferentes cenários	BMVPA apresentou melhor desempenho em 9 de 10 cenários analisados.
(SHIN; BAEK; RHEE, 2020)	Otimização do layout de turbinas offshore	EA e PSO	Parque de 60 MW na Coreia do Sul	Layout otimizado aumentou a AEP e o fator de capacidade do parque.
(CABRAL, 2021)	Otimização do layout e sistema coletor offshore	BA, BAT-mod, GWO e PSO	Parque offshore no Nordeste brasileiro	BAT-mod apresentou melhor convergência e redução de 10,66% nas perdas por wake.
(AMOUSSOU <i>et al.</i> , 2023)	Dimensionamento de sistema híbrido renovável	MFO, I-GWO, MVO e AVOA	Sistema solar-eólico com armazenamento	MFO apresentou menor custo total do ciclo de vida.
Este trabalho	Otimização do layout de parques eólicos offshore	BA, GWO e MVO	Dois parques eólicos offshore	MVO apresentou melhor desempenho nos dois parques analisados, com maior potência média gerada em comparação aos algoritmos BA e GWO.

Fonte: Elaborado pela autora.

4 MÉTODOS DE OTIMIZAÇÃO

Os métodos de otimização constituem um conjunto de técnicas matemáticas e computacionais desenvolvidas para identificar, entre inúmeras possibilidades, a solução mais adequada para um problema específico, considerando suas restrições e objetivos. Essas técnicas são aplicadas em diversas áreas do conhecimento, como engenharia, economia, agricultura, logística e transporte, devido à sua capacidade de apoiar decisões complexas. Na engenharia, por exemplo, são essenciais para aprimorar o desempenho de sistemas; na economia, contribuem para a maximização de lucros ou a redução de custos; na agricultura, auxiliam no planejamento de colheitas e no uso eficiente de recursos; e, na logística, permitem aperfeiçoar rotas e processos de distribuição, reduzindo tempo e despesas.

O propósito central de qualquer método de otimização é encontrar a melhor solução possível para uma Função Objetivo (FOB), seja buscando seu valor máximo ou mínimo, sempre respeitando um conjunto de restrições predefinidas. Essa função pode representar diferentes metas, como aumento de lucro, diminuição de custos ou melhoria de desempenho de sistemas complexos. Em muitos casos, os problemas podem envolver múltiplos objetivos, dando origem aos chamados modelos multiobjetivo, nos quais diferentes critérios precisam ser considerados simultaneamente.

A escolha do método mais adequado depende das particularidades do problema e dos recursos computacionais disponíveis (OLIVIERI, 2004). De forma geral, os métodos de otimização podem ser divididos em duas categorias: determinísticos, que apresentam sempre o mesmo resultado a partir de uma mesma condição inicial, e estocásticos/probabilísticos, cujo desempenho pode variar devido à presença de aleatoriedade no processo de busca.

Além dessas abordagens, há também os métodos heurísticos, que utilizam estratégias exploratórias e sucessivas, aproximações com base em experiência ou regras práticas para localizar soluções de boa qualidade. Tais métodos não garantem a obtenção do ótimo global, mas são amplamente utilizados pela capacidade de contornar funções complexas com múltiplos mínimos e máximos locais. Podem ainda ser determinísticos ou estocásticos, dependendo da forma como a aleatoriedade é incorporada ao algoritmo.

Com o passar dos anos, diversas metaheurísticas inspiradas em fenômenos naturais foram desenvolvidas. Esses métodos baseiam-se em princípios biológicos, comportamentais ou ecológicos, operando por meio de populações de soluções que interagem e evoluem segundo regras de transição, mecanismos probabilísticos e estratégias de penalização para violações de restrições.

Como não existe uma técnica universal capaz de resolver eficientemente todos os tipos de problema, diferentes algoritmos foram concebidos para lidar com desafios variados. Entre os métodos baseados na natureza mais conhecidos destacam-se: GA (HOLLAND, 1992), *Ant Colony Optimization* (ACO) (DORIGO, 1992), PSO (KENNEDY;

EBERHART, 1995), *Bat Algorithm* (BA) (YANG, 2010) e o *Grey Wolf Optimizer* (GWO) (MIRJALILI; MIRJALILI; LEWIS, 2014).

Esses algoritmos populacionais possuem características particularmente vantajosas, como a habilidade de explorar diversas regiões do espaço de busca, lidar com parâmetros contínuos e discretos, e identificar múltiplas soluções promissoras em nível global. Entretanto, apresentam também limitações, como maior demanda computacional e dependência dos parâmetros iniciais.

No contexto desta dissertação, são analisados e comparados três métodos de otimização inspirados na natureza: BA, GWO e o MVO. A escolha dos algoritmos BA e GWO foi motivada por sua aplicação em estudos relacionados à otimização de *layout* de parques eólicos descritos na literatura.

Por outro lado, o MVO ainda possui pouca exploração nesse tipo específico de problema. Dessa forma, sua inclusão neste trabalho teve como objetivo avaliar seu desempenho na otimização do *layout* de parques eólicos e verificar seu potencial quando comparado a algoritmos já consolidados na literatura.

4.1 BAT ALGORITHM

O BA é um método metaheurístico de otimização proposto por (YANG, 2010), inspirado no comportamento de ecolocalização dos morcegos microchiroptera. Esses morcegos utilizam pulsos ultrassônicos curtos para detectar obstáculos, localizar presas e estimar distâncias por meio da análise do eco refletido. Ao traduzir esse comportamento para o domínio matemático, Yang criou um algoritmo que equilibra exploração global e busca local refinada, com notável eficiência e simplicidade de implementação.

O BA foi desenvolvido para resolver problemas contínuos de otimização, inclusive funções multimodais complexas, e desde sua formulação tem sido amplamente aplicado em engenharia, controle, aprendizado de máquina e problemas combinatórios.

O princípio do BA está na capacidade dos morcegos de ajustar dinamicamente a frequência dos pulsos emitidos, o nível de intensidade (*loudness*) e a taxa de emissão de pulso, de acordo com a proximidade do alvo. Analogamente, no espaço de busca, cada morcego representa uma solução candidata, que se move conforme a sua velocidade, frequência e qualidade (aptidão da solução). Essas características permitem que o BA se comporte como uma população de agentes inteligentes, que interagem cooperativamente para localizar o ótimo global.

Cada morcego i é caracterizado pelos seguintes parâmetros:

- posições iniciais dos morcegos $X_i \in \mathbb{R}^d$, representando uma solução candidata, em que d corresponde à dimensão do problema de otimização (número de variáveis de decisão);

- velocidade V_i ;
- frequência de som f_i ;
- taxa de emissão de pulsos r_i ;
- amplitude do pulso A_i .

As Equações 4.1, 4.2 e 4.3 descrevem o comportamento dinâmico do algoritmo, em que as frequências f_i , velocidades V_i e posições X_i são continuamente ajustadas para direcionar a busca em direção à melhor solução global X_* . A variável aleatória β controla a diversidade das frequências, permitindo alternar entre movimentos exploratórios amplos e ajustes locais mais refinados.

$$f_i = f_{\min} + (f_{\max} - f_{\min})\beta, \quad \beta \sim U(0,1) \quad (4.1)$$

$$V_i^{t+1} = V_i^t + (X_i^t - X_*^t) \cdot f_{ri} \quad (4.2)$$

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (4.3)$$

No início do processo de otimização do BA, é definido o número de morcegos (n) e as taxas de decréscimo da amplitude do pulso α e de aumento da emissão de pulsos λ . As posições iniciais dos morcegos (X_i) e seus parâmetros individuais, sendo eles: velocidade (V_i), frequência (f_i), taxa de emissão de pulsos (r_i) e amplitude do pulso (A_i), são determinadas. Essas posições (X_i) representam as possíveis soluções, que são avaliadas e classificadas pelo valor da FOB. A melhor posição avaliada (X_*) identifica o melhor morcego da população.

Em seguida, o algoritmo começa seu processo iterativo, e o critério de parada pode ser definido pelo número de iterações, estagnação ou tempo de execução. A cada iteração t , as frequências (f_{ri}), velocidades (V_i^{t+1}) e posições (X_i^{t+1}) dos morcegos são atualizadas como apresentado nas Equações 4.2 e 4.3, em que a frequência do morcego i está entre o valor mínimo (f_{\min}) e máximo (f_{\max}) e β é um número aleatório pertencente ao intervalo $[0,1]$ em que X_* é a melhor solução global encontrada até o momento. A variável aleatória β controla a diversidade de frequências, o que permite alternar entre movimentos exploratórios amplos e ajustes finos locais.

Para refinar a solução, o BA utiliza uma etapa de busca local adaptativa. Quando um morcego encontra uma solução promissora, ele realiza um pequeno ajuste local segundo a equação 4.4:

$$X_{\text{new}} = X_* + \epsilon A^t, \quad (4.4)$$

onde $\epsilon \in [-1,1]$ é um número aleatório e A^t é a média da intensidade de todos os morcegos na iteração t . Esse mecanismo é análogo ao resfriamento adaptativo do *Simulated Annealing*, pois o parâmetro A_i decresce a cada iteração, reduzindo gradualmente a amplitude dos movimentos e favorecendo a convergência.

A intensidade A_i e a taxa de emissão r_i são ajustadas dinamicamente ao longo das iterações, à medida que as soluções evoluem, conforme mostram às Equações 4.5 e 4.6:

$$A_i^{t+1} = \alpha A_i^t \quad (4.5)$$

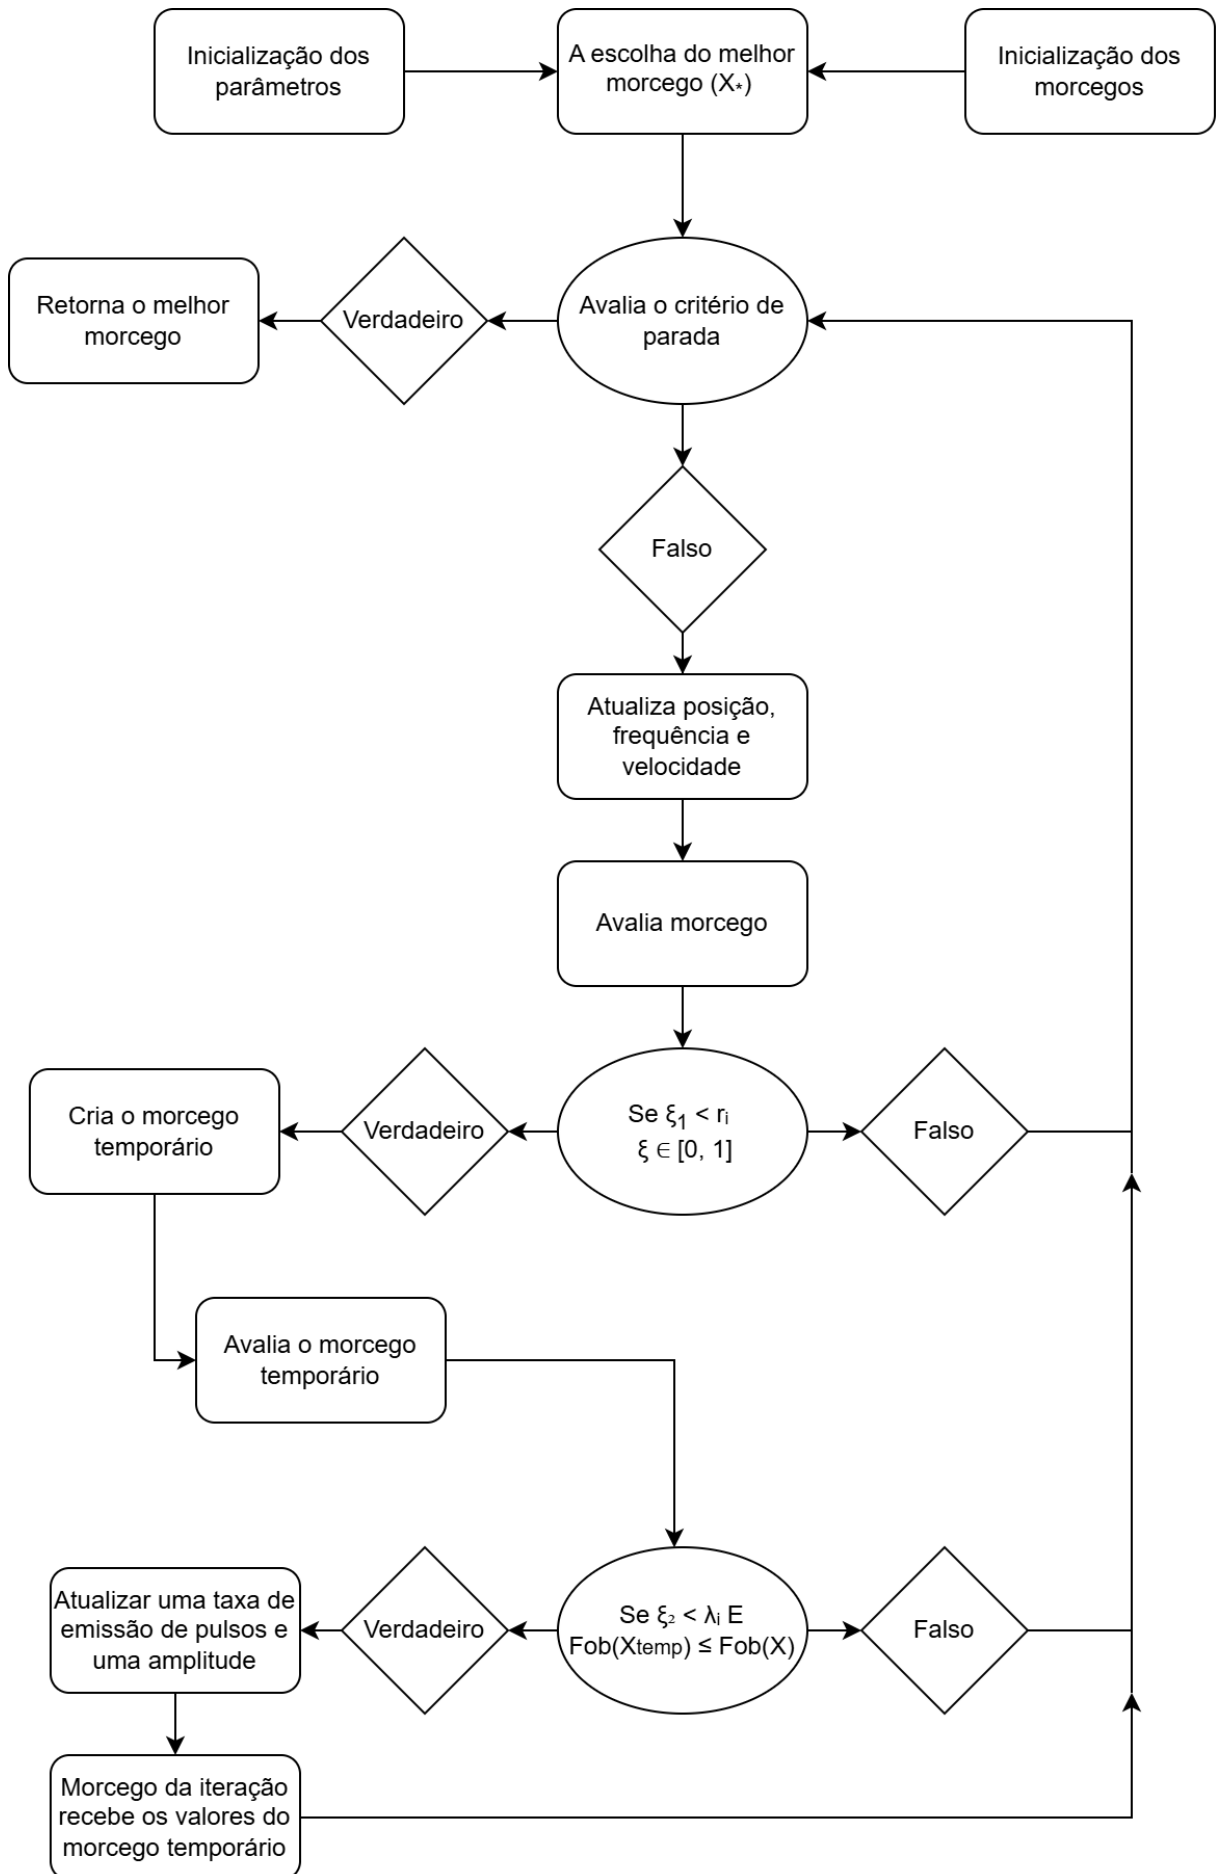
$$r_i^{t+1} = r_i^0 [1 - \exp(-\gamma t)] \quad (4.6)$$

onde:

- $\alpha \in (0,1)$ controla o decaimento da *loudness* (análogo ao fator de resfriamento);
- $\gamma > 0$ regula o crescimento da taxa de emissão de pulsos.

Valores típicos usados pelo autor são $\alpha = 0.9$ e $\gamma = 0.9$. Com o avanço das iterações, $A_i \rightarrow 0$ e $r_i \rightarrow 1$, refletindo o comportamento real dos morcegos, que emitem mais pulsos de baixa intensidade conforme se aproximam do alvo.

A Figura 14 apresenta o fluxograma do *Bat Algorithm*, ilustrando visualmente as principais etapas do processo iterativo descrito.

Figura 14 – Fluxograma do *Bat Algorithm*.

O BA foi comparado com GA e PSO (YANG, 2010). Os resultados médios de 100 execuções, considerando uma tolerância de $\varepsilon \leq 10^{-5}$, demonstraram que o BA apresenta menor número de avaliações de função e maior taxa de sucesso na localização do ótimo global.

Portanto, o BA pode ser visto como uma generalização dessas abordagens, combinando elementos de ambas com o controle adaptativo de frequência e pulsos.

O BA apresenta um equilíbrio eficaz entre exploração e intensificação, utilizando mecanismos inspirados na ecolocalização para ajustar dinamicamente a busca. Sua estrutura simples e adaptável, aliada à capacidade de escapar de ótimos locais, o torna uma poderosa ferramenta de otimização.

Os estudos iniciais (YANG, 2010) demonstraram que o BA supera algoritmos como GA e PSO em precisão e velocidade de convergência.

4.2 GREY WOLF OPTIMIZER

O GWO, proposto por (MIRJALILI; MIRJALILI; LEWIS, 2014), é um algoritmo de otimização inspirado no comportamento social e nas estratégias de caça dos lobos cinzentos (*Canis lupus*). O GWO modela matematicamente a hierarquia social e as fases de caça (cercar, perseguir e atacar a presa), traduzindo essas etapas em mecanismos de exploração e exploração intensiva do espaço de busca.

Na natureza, os lobos organizam-se em grupos com estrutura hierárquica. O GWO representa essa hierarquia por meio de quatro tipos de indivíduos: X_α , X_β , X_δ e X_ω , onde X_α representa o lobo alfa (melhor solução), X_β representa o lobo beta (segunda melhor solução), X_δ representa o lobo delta (terceira melhor solução) e X_ω representa os demais lobos da população. Os lobos α , β e δ guiam o movimento dos demais em direção à presa (ótimo global).

Para gerar uma nova solução, são calculados vetores de distância entre a solução atual X^t e as três melhores α , β , δ , ordenadas de forma decrescente em termos de avaliação. Essas distâncias são calculadas conforme a Equação 4.7. Os vetores \vec{C} assumem valores \vec{C}_1 , \vec{C}_2 e \vec{C}_3 , respectivamente, sendo eles vetores da mesma dimensão das soluções. Esses vetores \vec{C} , são compostos por valores aleatórios entre 0 e 2. Quanto a \vec{X} , assumem os valores de \vec{X}_α , \vec{X}_β e \vec{X}_δ , que representam as posições das soluções α , β e δ , respectivamente.

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (4.7)$$

e a atualização da posição do lobo é dada pela Equação 4.8

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (4.8)$$

onde:

$$\vec{A} = 2a \cdot \vec{r}_1 - a, \quad \vec{C} = 2 \cdot \vec{r}_2 \quad (4.9)$$

Na Equação 4.9 vetores \vec{r}_1 e \vec{r}_2 são números aleatórios uniformes no intervalo $[0,1]$, e o parâmetro a é reduzido linearmente de 2 para 0 ao longo das iterações, controlando o equilíbrio entre exploração (busca global) e exploração local.

Com base nas distâncias calculadas pela Equação 4.8, são determinadas possíveis soluções representadas por \vec{X} , podendo assumir três posições: \vec{X}_1 , \vec{X}_2 e \vec{X}_3 , como na Equação 4.10. O vetor \vec{A} , que pode assumir os valores \vec{A}_1 , \vec{A}_2 e \vec{A}_3 , é composto por números aleatórios entre -1 e 1, multiplicados pelo fator a_{exp} , que decresce linearmente de 2 a 0. Inicialmente, esses vetores são aleatórios entre -2 e 2, mas esse intervalo diminui ao longo das iterações do processo. A partir da média aritmética dessas três novas posições, calcula-se a nova solução, conforme demonstrado pela Equação 4.11. As etapas de busca local e global neste algoritmo estão relacionadas aos valores de \vec{A}_1 , \vec{A}_2 e \vec{A}_3 . Quando os módulos desses vetores são maiores do que 1, as novas posições são obtidas afastando-se da posição considerada como o ponto ótimo; caso contrário, as novas posições são obtidas aproximando-se dela.

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha, \quad \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta, \quad \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \quad (4.10)$$

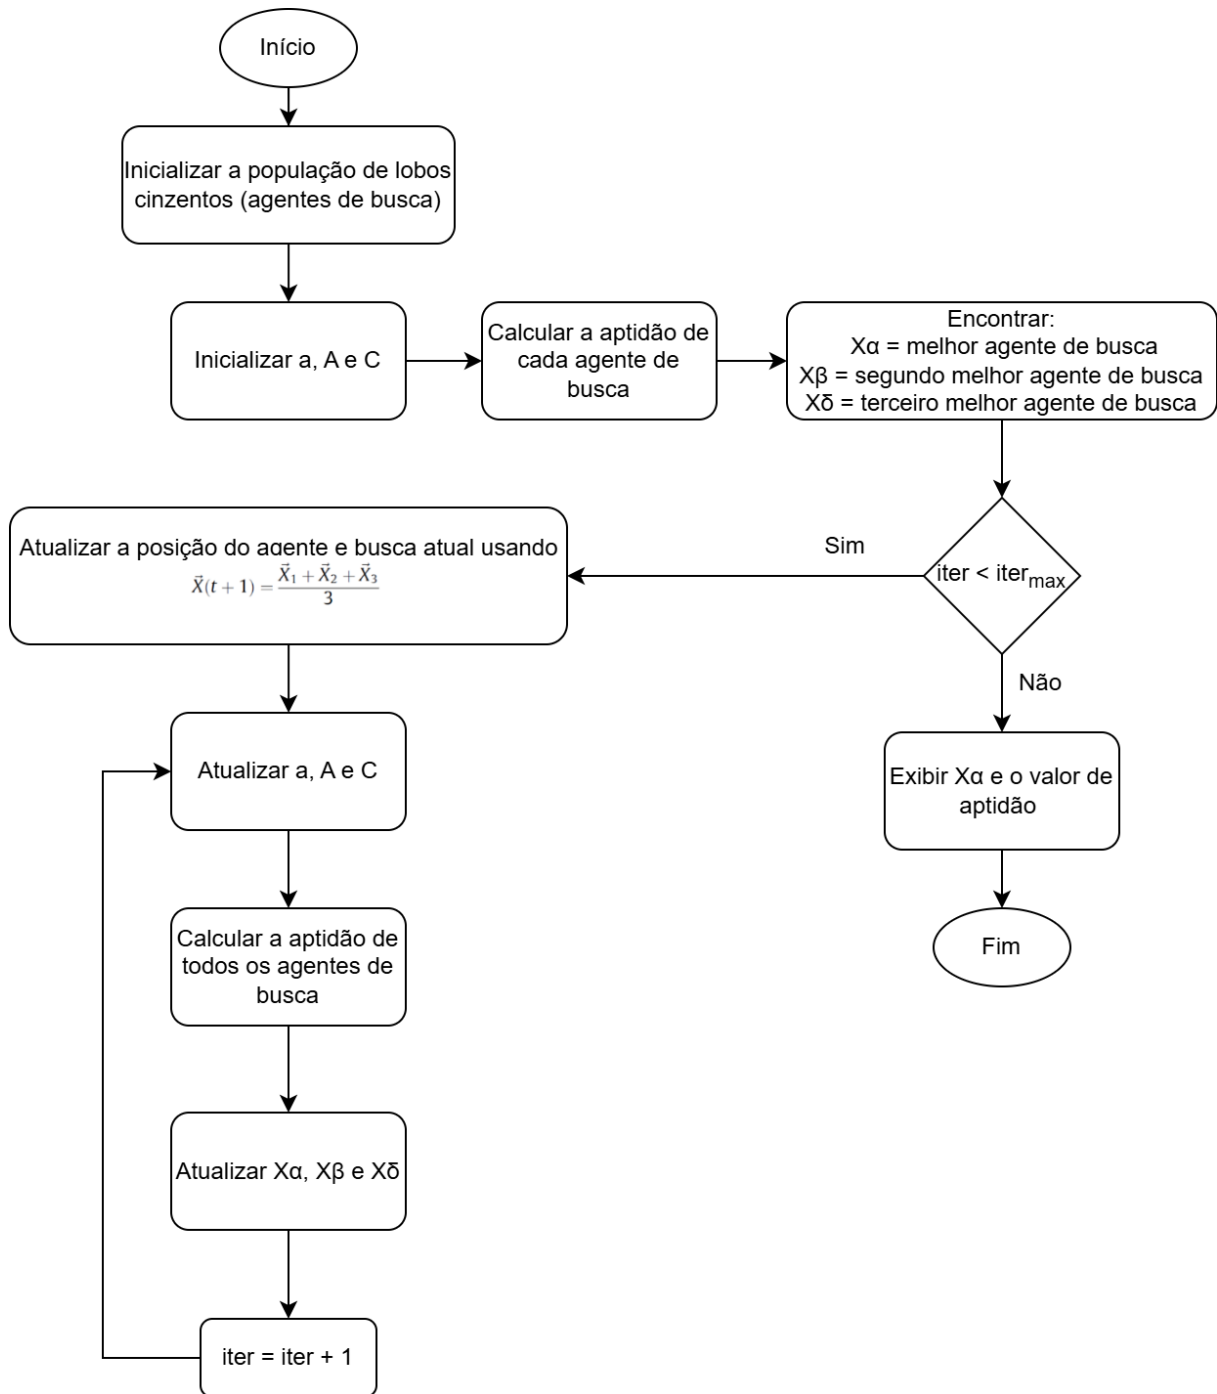
$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (4.11)$$

Essa equação garante que cada agente busque o ótimo global com base na experiência coletiva dos lobos líderes.

onde:

- $\vec{X}(t)$: vetor posição de um lobo no espaço de busca na iteração t ;
- \vec{X}_α , \vec{X}_β e \vec{X}_δ : posições das três melhores soluções da população;
- \vec{X}_1 , \vec{X}_2 e \vec{X}_3 : posições intermediárias calculadas a partir dos lobos líderes;
- \vec{D} : vetor distância entre a posição atual do lobo e a presa;
- \vec{A} e \vec{C} : vetores coeficientes que controlam o movimento dos lobos;
- \vec{r}_1 e \vec{r}_2 : vetores aleatórios com valores uniformemente distribuídos no intervalo $[0,1]$;
- a : parâmetro de controle que decresce linearmente de 2 para 0 ao longo das iterações;
- t : índice de iteração do algoritmo.

O algoritmo GWO foi avaliado em 29 funções de benchmark (MIRJALILI; MIRJALILI; LEWIS, 2014), abrangendo funções unimodais, multimodais, de dimensão fixa e compostas. Os resultados obtidos demonstraram uma alta capacidade de exploração nas funções multimodais, boa intensificação da busca nas funções unimodais, efetiva evasão de mínimos locais nas funções compostas e rápida convergência em problemas de engenharia. Devido à sua simplicidade matemática, ao reduzido número de parâmetros de controle e ao forte desempenho apresentado, o GWO é amplamente reconhecido como uma metaheurística eficiente para problemas de otimização contínua e restrita. A Figura 15 apresenta o fluxograma do algoritmo, ilustrando o processo geral de sua execução.

Figura 15 – Fluxograma do *Grey Wolf Optimizer*.

Fonte: Elaborado pela autora.

4.3 MULTIVERSE OPTIMIZATION ALGORITHM

O MVO, proposto por (MIRJALILI; MIRJALILI; HATAMLOU, 2016), é uma metaheurística baseada em população inspirada na teoria do multiverso na física. De acordo com essa teoria, múltiplos universos coexistem simultaneamente, cada um com propriedades distintas. O MVO utiliza três fenômenos cosmológicos para orientar o processo de busca: *white holes* (buracos brancos), *black holes* (buracos negros) e *wormholes*

(buracos de minhoca). Esses mecanismos definem os processos de exploração e exploração intensiva.

Cada solução candidata é interpretada como um universo, e cada variável da solução é tratada como um objeto desse universo. O valor da função objetivo é denominado taxa de inflação, sendo que soluções de melhor qualidade apresentam maior taxa de inflação. Além disso, o MVO utiliza o termo “tempo” no lugar de “iteração”, mantendo consistência com a inspiração cosmológica.

A população é organizada em uma matriz U , conforme a Equação 4.12, onde n é o número de universos e d o número de variáveis do problema:

$$U = \begin{pmatrix} x_1^1 & x_1^2 & \dots & x_1^d \\ x_2^1 & x_2^2 & \dots & x_2^d \\ \vdots & \vdots & \ddots & \vdots \\ x_n^1 & x_n^2 & \dots & x_n^d \end{pmatrix} \quad x_i^j = \begin{cases} x_k^j & \text{se } r_1 < \text{NI}(U_i), \\ x_i^j & \text{se } r_1 \geq \text{NI}(U_i), \end{cases} \quad (4.12)$$

onde $r_1 \sim U(0,1)$ e $\text{NI}(U_i)$ é a taxa de inflação normalizada do universo i . O índice k representa um universo selecionado via roleta.

A fase de exploração se baseia na interação entre buracos brancos e buracos negros. Universos com maior taxa de inflação têm maior probabilidade de gerar buracos brancos, enquanto universos com taxas de inflação menores tendem a receber objetos por buracos negros.

O mecanismo de roleta é utilizado para selecionar universos com base na probabilidade proporcional à taxa de inflação normalizada. Assim, objetos tendem a ser transferidos dos melhores universos para os piores, promovendo uma troca de informação que garante grande capacidade exploratória. Esse processo permite perturbações abruptas na configuração das soluções, essenciais para evitar estagnação em ótimos locais.

Os buracos de minhoca são responsáveis pela exploração intensiva ao redor do melhor universo encontrado até o momento, independentemente da qualidade do universo atual. Essa operação simula conexões instantâneas entre universos distantes.

A atualização de uma variável utilizando buracos de minhoca segue a lógica da Equação 4.13.

$$x_i^j(t+1) = \begin{cases} x_i^{\text{best}} + TDR \cdot (ub_i - lb_i) \cdot r_3, & \text{se } r_2 < WEP, \\ x_i^{\text{best}} - TDR \cdot (ub_i - lb_i) \cdot r_3, & \text{se } r_2 \geq WEP, \end{cases} \quad (4.13)$$

com $r_2, r_3 \sim U(0,1)$, $[lb_i, ub_i]$ sendo os limites da variável e TDR controlando a distância de deslocamento. Assim, o MVO garante intensificação da busca ao redor da melhor solução, ao mesmo tempo mantendo diversidade populacional.

Dois coeficientes adaptativos controlam a intensidade das atualizações por buracos de minhoca, conforme a Equação 4.14.

$$\text{WEP} = \min + l \left(\frac{\max - \min}{L} \right), \quad \text{TDR} = 1 - \left(\frac{l^{1/p}}{L^{1/p}} \right). \quad (4.14)$$

onde:

- U : matriz que representa a população de universos;
- n : número de universos (tamanho da população);
- d : número de variáveis do problema de otimização;
- x_i^j : valor da j -ésima variável no universo i ;
- $\text{NI}(U_i)$: taxa de inflação normalizada do universo i ;
- x_i^{best} : posição correspondente ao melhor universo encontrado até o momento;
- r_1, r_2, r_3 : números aleatórios uniformemente distribuídos no intervalo $[0,1]$;
- $[lb_i, ub_i]$: limites inferior e superior da variável i ;
- WEP: probabilidade de existência de buracos de minhoca;
- TDR: taxa de distância de viagem;
- l : tempo atual (iteração do algoritmo);
- L : número máximo de iterações;
- p : parâmetro que controla a taxa de decaimento da TDR.

A probabilidade de existência de buracos de minhoca (WEP) cresce linearmente ao longo do tempo, aumentando a exploração intensiva nas últimas iterações. Já a taxa de distância de viagem (TDR) diminui progressivamente, garantindo refinamento da busca próxima ao melhor universo.

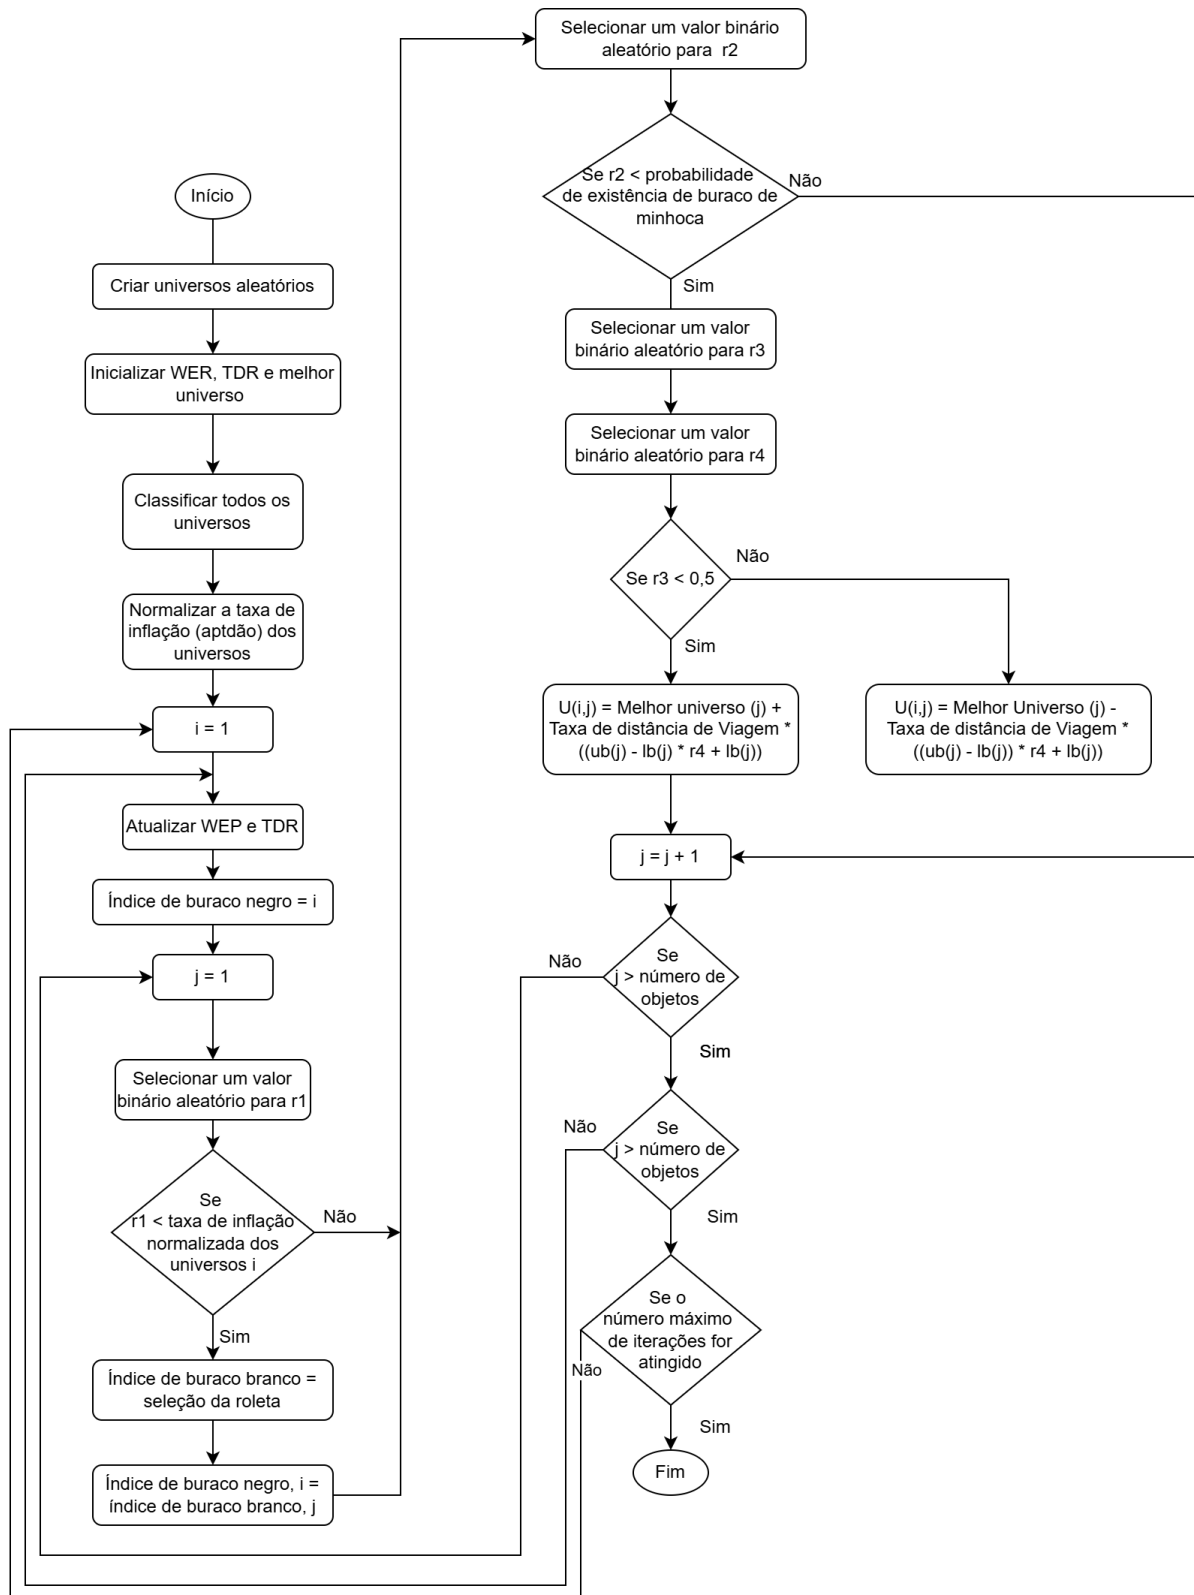
Parâmetros típicos:

$$\min = 0.2, \quad \max = 1.$$

O MVO combina mecanismos globais (buracos brancos e buracos negros) e locais (buracos de minhoca), resultando em: ampla exploração no início da busca, intensificação progressiva próxima às melhores soluções, diversidade preservada durante todo o processo e capacidade robusta de escapar de ótimos locais. Essa combinação permite que o algoritmo apresente desempenho competitivo em uma ampla gama de problemas.

A Figura 16 descreve, passo a passo, o fluxograma do algoritmo MVO.

Figura 16 – Fluxograma do *Multiverse Optimization Algorithm*.



Fonte: Elaborado pela autora.

4.4 MECANISMOS DE BUSCA DAS METAHEURÍSTICAS

Em algoritmos metaheurísticos, é comum analisar o comportamento de busca a partir do equilíbrio entre exploração global e intensificação local. A exploração global está associada à capacidade do algoritmo de investigar diferentes regiões do espaço de busca, enquanto a exploração local está relacionada ao refinamento de soluções promissoras. Com base nesses conceitos amplamente discutidos na literatura de otimização, a Tabela 2 apresenta uma comparação entre os algoritmos considerados neste trabalho quanto aos seus mecanismos de movimentação, exploração global e intensificação local.

Tabela 2 – Comparação entre os algoritmos BA, GWO e MVO quanto aos mecanismos de busca.

Algoritmo	Movimentação	Exploração global	Exploração local
BA	Atualiza posições e velocidades, utilizando frequência para controlar o tamanho do passo. Os parâmetros loudness (A) e pulse rate (r) regulam a aceitação de soluções e o nível de aleatoriedade ao longo das iterações.	Elevada no início do processo, pois frequências altas e maior aleatoriedade permitem grandes deslocamentos e ampla varredura do espaço de busca.	Com o avanço das iterações, A tende a diminuir e r a aumentar, promovendo refinamento progressivo em torno da melhor solução encontrada.
GWO	As soluções são atualizadas com base nos três melhores indivíduos da população (α , β e δ), simulando o comportamento hierárquico de caça dos lobos.	Inicialmente elevada, pois o parâmetro a assume valores altos, resultando em movimentos amplos e busca global efetiva.	À medida que a decresce, os passos tornam-se menores, conduzindo à convergência gradual para a região ocupada pelos líderes.
MVO	Baseia-se na interação entre universos por meio de dois mecanismos principais: troca probabilística de variáveis via <i>white/black holes</i> (baseada em ranking) e aproximação do melhor universo via <i>wormholes</i> .	A diversificação ocorre pela recombinação probabilística de variáveis, onde universos com melhor desempenho influenciam os demais, promovendo ampla exploração do espaço.	A intensificação é controlada pelos <i>wormholes</i> , cujo efeito aumenta com o crescimento do WEP e a redução do TDR, direcionando a busca para a vizinhança da melhor solução.

Fonte: Elaborado pela autora.

5 METODOLOGIA

5.1 PARÂMETROS ADOTADOS

Os parâmetros específicos de cada algoritmo estão apresentados na Tabela 3. Esses parâmetros são fundamentais para o desempenho das metaheurísticas, pois controlam o equilíbrio entre exploração global e intensificação local do espaço de busca, influenciando diretamente a convergência e a qualidade das soluções obtidas.

Tabela 3– Parâmetros utilizados nos algoritmos BA, GWO e MVO.

Parâmetro	BA	GWO	MVO
Tamanho da população (N)	250	250	250
Número máximo de iterações ($Iter_{max}$)	250	250	250
Frequência mínima (f_{min})	0	–	–
Frequência máxima (f_{max})	2	–	–
Loudness inicial (A_0)	1	–	–
Taxa de emissão de pulso inicial (r_0)	0	–	–
Fator de redução do loudness (α)	0,9	–	–
Fator de aumento da taxa de pulso (γ)	0,9	–	–
Coefficiente de exploração (\bar{a})	–	decrece linearmente de 2 \rightarrow 0	–
Probabilidade de buraco de minhoca (WEP)	–	–	cresce linearmente
Valor mínimo de WEP (min)	–	–	0,2
Valor máximo de WEP (max)	–	–	1
Distância de viagem por buraco de minhoca (TDR)	–	–	diminui progressivamente

Fonte: Elaborado pela autora.

5.2 MATRIZ INTERFERÊNCIA - REPRESENTAÇÃO DA SOLUÇÃO

No programa desenvolvido, a avaliação de uma solução candidata é realizada por meio da matriz de interferência. Nessa formulação, o domínio do problema é discretizado em células, ou *bits*, sendo que cada *bit* equivale a uma variável binária, indicando a presença (valor 1) ou a ausência (valor 0) de um aerogerador naquela posição. A matriz de interferência tem a função de quantificar a interferência aerodinâmica provocada pela ativação de uma variável binária sobre as demais variáveis do domínio.

A interferência é calculada considerando todos os ângulos de incidência do vento, de acordo com o modelo de *wake effect* adotado, permitindo que a direção do vento seja incorporada diretamente ao processo decisório da heurística. Dessa forma, a matriz orienta a ativação ou desativação das variáveis binárias de modo a reduzir perdas aerodinâmicas e favorecer soluções energeticamente mais eficientes.

Para ilustrar essa modelagem, é apresentada uma matriz de interferência construída a partir de uma malha representativa de um parque eólico de 3×3 bits, com espaçamento de 900 metros entre células, conforme mostrado na Figura 17. Essa estrutura é utilizada para avaliar diferentes configurações de variáveis binárias, servindo como base para a

escolha das posições mais adequadas dos aerogeradores em função da direção do vento predominante, com o objetivo de maximizar a potência total do parque eólico.

Figura 17 – Parque 3x3

6	7	8
3	4	5
0	1	2


Fonte: Elaborado pela autora.

A matriz de interferência associada a esse caso representa o impacto que a ativação de uma variável binária, identificada pela linha da matriz, exerce sobre as demais variáveis binárias correspondentes às colunas, considerando uma direção específica do vento. Cada elemento da matriz expressa, portanto, o nível de redução da velocidade do vento — e, conseqüentemente, da potência gerada — decorrente do efeito de esteira (*wake effect*) entre aerogeradores.

Como exemplo, quando o vento incide na direção norte-sul, conforme ilustrado na Figura 18, a ativação da variável binária correspondente à posição 6 provoca maior interferência sobre as variáveis associadas às células 3 e 0, sendo o efeito mais pronunciado na célula imediatamente a jusante. Essa informação é explorada no processo de alocação para evitar combinações desfavoráveis de variáveis binárias e priorizar configurações estratégicas, como a apresentada na Figura 19.


Nesse contexto, a alocação dos aerogeradores resulta da seleção adequada das variáveis binárias em função da direção do vento, buscando minimizar as perdas por interferência aerodinâmica e, conseqüentemente, maximizar a produção de energia do parque eólico.

Figura 18 – Representação esquemática dos ventos norte-sul e sua interferência.



Fonte: Elaborado pela autora.

Figura 19 – Posição estratégica dos aerogeradores com ventos norte-sul.




Fonte: Elaborado pela autora.

De forma complementar, analisa-se o comportamento da matriz de interferência quando o vento incide em uma direção diagonal, especificamente do nordeste para o sudoeste. Nesse caso, a propagação do *wake effect* não ocorre exclusivamente ao longo das direções vertical ou horizontal da malha, mas segue a direção diagonal imposta pelo escoamento do vento.

Conforme ilustrado na Figura 20, a ativação de uma variável binária associada a uma célula localizada a montante passa a influenciar as células posicionadas diagonalmente a jusante. Como exemplo, a ativação da variável correspondente à posição 8 resulta em interferência sobre as posições 4 e 0, sendo o impacto mais significativo na célula mais próxima ao aerogerador causador e decrescente à medida que a distância aumenta.

Esse comportamento evidencia que a matriz de interferência assume padrões distintos conforme a direção de incidência do vento, reforçando a importância de considerar múltiplos ângulos no processo de avaliação das soluções candidatas. Dessa forma, a metaheurística torna-se capaz de evitar arranjos desfavoráveis não apenas em alinhamentos ortogonais, mas também em configurações diagonais, ao considerar um conjunto de múltiplos ângulos de incidência do vento, contribuindo para a redução das perdas aerodinâmicas e para a maximização da potência total do parque eólico.

Figura 20 – Representação esquemática dos ventos nordeste-sudoeste e sua interferência.



Fonte: Elaborado pela autora.

5.3 FUNÇÃO OBJETIVO

A minimização da função objetivo em estudo consiste em maximizar a potência média produzida pelo parque eólico, levando em conta os diferentes ângulos de incidência do vento e suas respectivas probabilidades de ocorrência. A formulação matemática apresentada na Equação 5.1 enquadra o problema como uma tarefa de minimização. Nesse arranjo, como a potência aparece no denominador, a minimização implica, de forma indireta, na maximização do desempenho energético.

Na FOB, representada pela Equação 5.1, o termo N_{dir} representa o número total de direções consideradas na análise, enquanto P_d^{dir} e θ^d correspondem, respectivamente, à probabilidade e ao ângulo associados à direção d . A Equação 5.2 determina a velocidade do vento disponível na turbina de índice n para a direção d , adotando v_0^d como a velocidade incidente no parque e δ_n^d como o déficit de velocidade provocado pelo efeito de esteira. Esse termo representa a fração de redução da velocidade do vento na turbina analisada em decorrência da influência de aerogeradores posicionados a montante. A Equação 5.3, por sua vez, calcula a parcela de velocidade reduzida devido à influência de esteiras formadas por outros aerogeradores. Essa redução pode ser total, quando a esteira recobre completamente o rotor analisado, ou parcial, quando apenas parte da esteira atinge a turbina. A sobreposição entre a área atingida e a área total da esteira é quantificada pelo fator A_{in}/A_T , onde A_{in} é a área de interseção da esteira com o rotor e A_T é a área total de expansão da esteira.

$$MinFOB = \frac{Pen_L}{\sum_{d=1}^{N_{dir}} P_d^{dir} \cdot \sum_{n=1}^{N_T} P(v_n^d)} \quad (5.1)$$

A velocidade resultante em cada turbina é obtida por:

$$v_n^d = v_0^d \cdot (1 - \delta_n^d) \quad \forall n, d \quad (5.2)$$

A redução causada pelo *wake effect* é dada por:

$$\delta_n^d = \sum_{n=1}^{N_T} \frac{A_{in}(\theta^d)}{A_T} \cdot \left(1 - \frac{v_n(\theta^d)}{v_0^d}\right)^2 \quad \forall n, d \quad (5.3)$$

Como parte da modelagem, estabelece-se a restrição de que dois ou mais aerogeradores não podem ocupar a mesma posição na malha, evitando sobreposições físicas. Assim, sempre que tal violação ocorrer durante a avaliação da solução, os aerogeradores são redistribuídos aleatoriamente, e a solução é novamente verificada.

Caso, mesmo após esse procedimento, a configuração permaneça em desacordo com as restrições de posicionamento, aplica-se uma penalidade (Pen_L) à função objetivo. A variável $n_{aero-irregular}$ representa o número de turbinas que apresentam posicionamento

irregular, incluindo casos de sobreposição entre aerogeradores ou alocação em posições inválidas da malha.

Quando não há violação das restrições, a penalidade assume valor unitário, não afetando o valor da função objetivo. Entretanto, quando são identificadas irregularidades no posicionamento das turbinas, o valor da penalidade é calculado conforme a Equação 5.4, aumentando proporcionalmente ao número de ocorrências registradas.

$$Pen_L = 100.000 \cdot n_{aero-irregular} + 1 \quad (5.4)$$

O valor do coeficiente de penalização foi definido de forma suficientemente elevado para garantir que soluções inviáveis apresentem desempenho inferior às configurações fisicamente válidas. Ressalta-se que esse parâmetro pode variar conforme a escala do problema ou o empreendimento analisado, sendo frequentemente ajustado de forma empírica em estudos de otimização.

5.4 WAKE EFFECT

Nesse estudo foi considerado um único modelo de *wake effect*, sendo este o de Jensen (JENSEN, 1983) por ser o mais utilizado na literatura. O *wake effect*, também conhecido como efeito de esteira ou enfraquecimento do vento, ocorre em parques eólicos quando o escoamento atmosférico perde energia após atravessar uma turbina, atingindo as turbinas posicionadas atrás dela com velocidade reduzida. Como consequência, as turbinas a jusante passam a operar com menor disponibilidade de vento e, portanto, geram menos potência. Além da redução da velocidade média do vento, a esteira produz uma região com maior turbulência, o que aumenta os esforços dinâmicos nas pás e nos componentes estruturais, contribuindo para maior desgaste ao longo da vida útil (PEREIRA, 2016). A Figura 21 ilustra visualmente esse comportamento aerodinâmico. Segundo este modelo, a esteira produzida por uma turbina eólica expande-se de forma linear, em função da variável da constante de decaimento da esteira. E a velocidade radial também é constante dentro da esteira e se expande radialmente com o mesmo coeficiente.

Figura 21 – Fenômeno do *wake effect*.



Fonte: (CHAMPEAU, 2024).

Entre os modelos de *wake effect* existentes, o mais difundido é o modelo proposto por Jensen. Esse modelo considera que a região de déficit de velocidade atrás da turbina se comporta como um cone que se expande gradualmente, assumindo que o déficit de velocidade diminui com o aumento da distância a jusante, caracterizando a recuperação progressiva da velocidade do escoamento.

A popularidade do modelo de Jensen se deve principalmente ao fato de depender de apenas um parâmetro ajustável: o coeficiente de decaimento da esteira, k . Esse coeficiente está relacionado tanto às características da turbina (como o coeficiente de empuxo) quanto à turbulência atmosférica. Valores elevados de turbulência fazem com que a esteira se dissipe mais rapidamente, reduzindo perdas entre turbinas; já condições de baixa turbulência tornam a recuperação da velocidade mais lenta. O raio da esteira a uma distância x atrás da turbina é dado pela Equação 5.5, onde R é o raio do rotor, x é a distância a jusante e k é o coeficiente de expansão da esteira. A velocidade a uma distância x é expressa no modelo de Jensen apresentado na Equação 5.6.

$$R(x) = R + kx \quad (5.5)$$

$$V(x) = V_0 \left(1 - \frac{1 - \sqrt{1 - C_t}}{\left(1 + 2k\frac{x}{D}\right)^2} \right) \quad (5.6)$$

Alguns autores sugerem valores típicos para k . Por exemplo, (GAUMOND *et al.*, 2012) recomenda $k = 0,05$ para parques *offshore* pequenos e $k = 0,04$ para grandes parques. Já (LI; WANG; LIU, 2013) indica valores entre 0,04 e 0,075. Segundo (HASOINE *et al.*, 2022), esse coeficiente pode ser calculado pela Equação 5.7, em que Z é a altura da nacela e Z_0 é a rugosidade da superfície.

$$k = \frac{0.5}{\ln\left(\frac{Z}{Z_0}\right)} \quad (5.7)$$

O fator de indução axial α representa a redução da velocidade do vento causada pela extração de energia pela turbina eólica no plano do rotor. Esse parâmetro descreve a fração da velocidade do escoamento incidente que é reduzida devido à presença do rotor. O coeficiente de empuxo C_t , por sua vez, representa a intensidade da força exercida pelo vento sobre o rotor na direção do escoamento. Esse coeficiente está associado à quantidade de energia cinética extraída do vento e, conseqüentemente, à intensidade da esteira gerada atrás da turbina. A relação entre o coeficiente de empuxo e o fator de indução axial pode ser expressa pela Equação 5.8. A partir dessa relação, a equação de velocidade na esteira do modelo de Jensen pode ser reescrita em função do fator de indução axial, resultando na expressão apresentada na Equação 5.9.

$$\alpha = \frac{1 - \sqrt{1 - C_t}}{2} \quad C_t = 4\alpha(1 - \alpha) \quad (5.8)$$

$$V(x) = V_0 \left(1 - \frac{2\alpha}{\left(1 + 2k\frac{x}{D}\right)^2} \right) \quad (5.9)$$

5.5 ESTUDO DE CASOS

Os estudos de caso desenvolvidos neste trabalho realizam uma comparação entre a potência média obtida pelos *layouts* em licenciamento no IBAMA e pelos *layouts* otimizados para duas áreas de interesse: o Parque Pedra Grande e o Parque Camocim. Para cada região avalia-se o desempenho do arranjo original e do arranjo otimizado utilizando três metaheurísticas: BA, GWO e MVO, em conjunto com um modelo de *wake effect*, o de Jensen.

Ambos os estudos utilizam como aerogerador de referência a turbina Haliade X da GE, prevista nos projetos originais. Foram considerados os seguintes parâmetros: potência nominal de 12 MW, raio de hélice de 107 metros, diâmetro do rotor de 220 metros, coeficiente de segurança igual a 0,60 e batimetria uniforme de 100 metros ao

longo de toda a área analisada. O coeficiente de segurança adotado foi utilizado para garantir uma margem mínima de espaçamento entre aerogeradores, reduzindo possíveis interferências físicas e operacionais entre turbinas. Já a batimetria uniforme de 100 metros foi assumida como simplificação de modelagem, permitindo que o estudo se concentre exclusivamente na análise do posicionamento dos aerogeradores, sem introduzir variações adicionais associadas à profundidade do leito marinho.

As turbinas foram modeladas como totalmente orientáveis, com capacidade de giro de 360 graus, permitindo o aproveitamento de ventos provenientes de qualquer direção.

Os processos de otimização realizados para os dois parques seguiram parâmetros idênticos, assegurando comparabilidade entre os resultados obtidos. Cada metaheurística foi executada 50 vezes, com 250 iterações por execução. A realização de múltiplas execuções independentes é uma prática comum em estudos envolvendo algoritmos metaheurísticos, uma vez que esses métodos possuem natureza estocástica e podem produzir resultados diferentes a cada execução. O número de 50 execuções foi adotado com o objetivo de garantir representatividade estatística dos resultados e reduzir a influência de soluções ocasionais.

As populações utilizadas foram compostas por 250 indivíduos em cada algoritmo. O número de iterações foi definido de forma empírica, com base em valores frequentemente adotados na literatura para algoritmos metaheurísticos, especialmente em aplicações envolvendo o BA e o GWO. Trabalhos anteriores indicam que esse número de iterações é suficiente para permitir a convergência dos algoritmos e garantir estabilidade estatística nos resultados, sem aumentar excessivamente o custo computacional. Dessa forma, o valor de 250 iterações foi adotado neste estudo e mantido de forma uniforme para todos os algoritmos analisados.


A implementação dos estudos foi realizada em um programa desenvolvido em linguagem Python. O espaço disponível para alocação dos aerogeradores foi representado como uma malha discreta cujas dimensões e resolução foram definidas como parâmetros de entrada. Quando uma célula da malha é ocupada, o aerogerador é posicionado no centro geométrico daquela célula.

Esta abordagem, embora adequada para fins de modelagem computacional, impõe limitações quanto à reprodução exata da malha e do *layout* constantes nos processos de licenciamento, o que pode dificultar a busca da solução ótima quando o algoritmo fica preso em regiões restritivas do espaço de busca. No Parque Pedra Grande, que possui aproximadamente 40% de posições classificadas como restritivas na malha, a geração aleatória da população inicial frequentemente resultava em soluções inviáveis. Embora a função de penalização seja aplicada para tratar tais violações, a elevada quantidade de regiões restritas pode levar os algoritmos a permanecerem por muitas iterações explorando soluções inviáveis.

Para reduzir esse efeito e preservar a metodologia original de otimização utilizada pelos autores, foi adotada uma estratégia de inicialização parcial da população. Assim, 60% dos indivíduos da população inicial foram posicionados de acordo com o *layout* previamente licenciado para o parque. Dessa forma, o algoritmo parte de uma solução viável conhecida, reduzindo problemas de estagnação em regiões restritivas e favorecendo a exploração de soluções próximas ao arranjo original.

As simulações foram executadas em um processador Intel Core i5 de décima primeira geração. Os dados de vento empregados neste estudo foram extraídos do Global Wind Atlas, uma plataforma gratuita que fornece informações de velocidade do vento, características do relevo e outros parâmetros essenciais para a avaliação do potencial eólico. As condições médias de vento para as áreas analisadas são apresentadas na Figura 22. Para o Parque Pedra Grande, a velocidade média incidente considerada foi de aproximadamente 10,15 m/s, enquanto para o Parque Camocim adotou-se uma velocidade média de cerca de 8,95 m/s.

Figura 22 – Rosa dos ventos do Parque Pedra Grande e do Parque Camocim



Fonte: Elaborado pela autora a partir de (Global Wind Atlas, 2025).

A otimização realizada concentrou-se exclusivamente na determinação da posição dos aerogeradores dentro da área do projeto, mantendo fixo o número total de turbinas previsto nos *layouts* originais de licenciamento. Não foram otimizados o sistema coletor de energia elétrica, a localização ou quantidade de subestações e tampouco foi conduzida uma análise financeira dos custos de implantação. Essas escolhas metodológicas são relevantes para a interpretação dos resultados e para a delimitação do escopo da pesquisa.

6 RESULTADOS E DISCUSSÕES


6.1 PARQUE PEDRA GRANDE

A primeira análise baseia-se no projeto do parque eólico *offshore* Pedra Grande, a cerca de 8 km da costa de Pedra Grande (RN). O projeto propõe a instalação de 52 aerogeradores distribuídos igualmente em 4 fileiras, ocupando uma área total de cerca de 260 km².

Para calcular a energia produzida pelo parque dentro do programa, o *layout* foi incorporado seguindo as restrições próprias do modelo computacional. Entre elas estão o espaçamento fixo entre os *bits* da malha e o posicionamento obrigatório dos aerogeradores exatamente no centro de cada célula. Para este estudo, a distância adotada entre os *bits* correspondeu a $4D$, em que D representa o diâmetro do rotor da turbina, prática comumente adotada em projetos de parques eólicos para reduzir perdas por *wake effect*. Cada *bit* é um quadrado de 900 metros de lado, com os aerogeradores posicionados no centro dos *bits*.


A Figura 23 ilustra o arranjo do parque conforme previsto no licenciamento, enquanto a Figura 24 exhibe a forma como esse arranjo pôde ser representado na ferramenta de simulação. A potência média calculada com esse *layout* é de 318,2003 MW. A comparação entre as figuras evidencia as limitações da abordagem em malha, que dificultam a reprodução fiel do *layout* original.

Figura 23 – *Layout* licenciado do Parque Pedra Grande



Fonte: Elaborado pela autora a partir de (IBAMA, 2025).

Figura 24 – Parque Pedra Grande no Programa desenvolvido.




Fonte: Elaborado pela autora.

A área inserida no programa foi modelada como um retângulo composto por 28×18 *bits*, totalizando 504 *bits*. Entretanto, devido ao fato de a área real possuir um formato trapezoidal, 216 *bits* precisaram ser excluídos, uma vez que não eram compatíveis com a geometria do projeto. O estudo propõe uma comparação da energia obtida pelo *layout* licenciado e do *layout* otimizado para a mesma região, sendo considerados os três diferentes modelos de otimização.


A Figura 25 e a Figura 26 exibem os *layouts* dos parques eólicos otimizados para os métodos do BA e do MVO, respectivamente. O GWO teve de *layout* ótimo o mesmo especificado, exibido na Figura 24.

Figura 25 – *Layout* otimizado pelo BA para o Parque Pedra Grande.



Fonte: Elaborado pela autora.

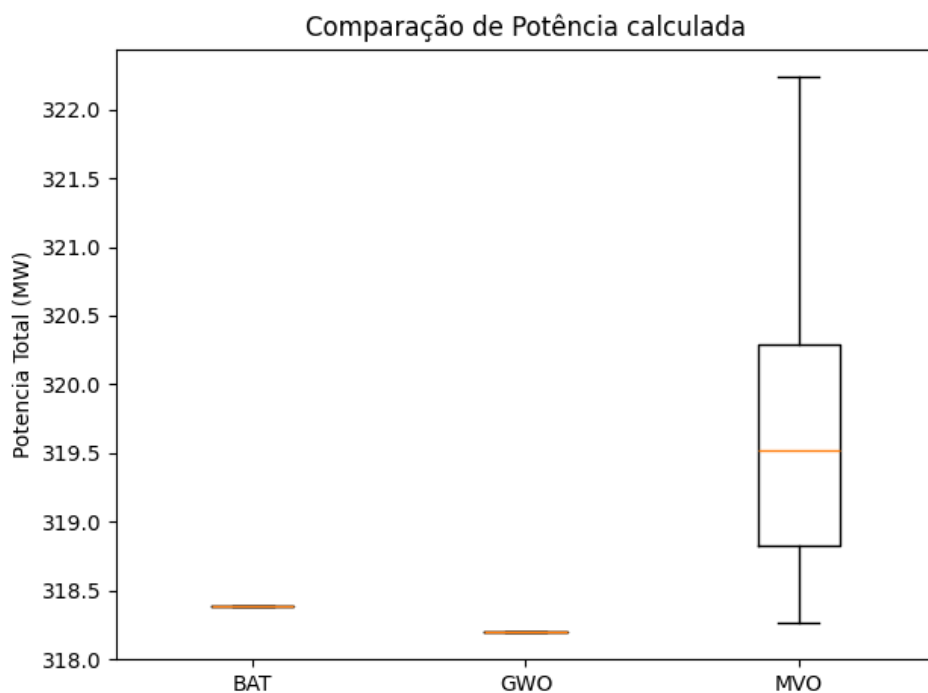
Figura 26 – *Layout* otimizado pelo MVO para o Parque Pedra Grande.



Fonte: Elaborado pela autora.

A análise dos três métodos de otimização evidencia diferenças importantes tanto no desempenho em termos de potência quanto no comportamento estatístico das execuções. O *boxplot* da potência, representado na Figura 27, mostra que o GWO apresenta o comportamento mais estável entre os métodos, com ausência de dispersão e convergência repetida para o mesmo valor. Já o BA mantém boa estabilidade, porém com leve variação entre as execuções. O MVO, por sua vez, apresenta a maior dispersão, consequência direta de sua característica exploratória, embora seja justamente esse comportamento que permite ao método alcançar as maiores potências máximas entre todos os experimentos.


Figura 27 – *Boxplot* da potência - Pedra Grande.



Fonte: Elaborado pela autora.

O *boxplot* da Figura 28 indica diferenças relevantes no custo computacional. O MVO é o método mais rápido, seguido pelo GWO, enquanto o BA apresenta o maior tempo médio de execução. Essa relação sugere que há um equilíbrio entre eficiência computacional e qualidade da solução: o GWO é eficiente e estável, o BA apresenta soluções intermediárias com maior custo de processamento, e o MVO, embora mais variável, produz os melhores valores de potência.

Figura 28 – *Boxplot* do tempo - Pedra Grande.



Fonte: Elaborado pela autora.

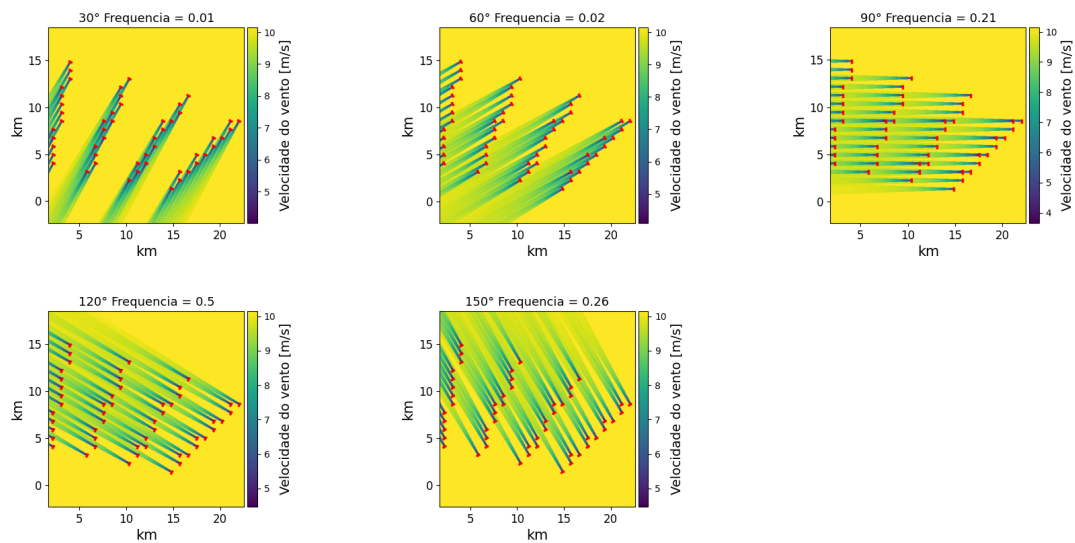
A Tabela 4 reforça essa interpretação. Ao comparar os resultados com o *layout* licenciado, que apresentou potência de 318,2003 MW, observa-se que os métodos BA e MVO foram capazes de melhorar a resposta original, enquanto o GWO reproduziu o mesmo valor, apresentando elevado nível de estabilidade entre as execuções. Os ganhos podem atingir até cerca de 4 MW, evidenciando uma melhora relevante no desempenho energético do parque. O MVO apresenta as maiores potências máxima e média, ainda que associado a uma maior variabilidade nos resultados; o BA mantém desempenho consistente, com valores estáveis e qualidade intermediária das soluções; enquanto o GWO reproduziu a mesma potência do *layout* licenciado.

Tabela 4 – Ganho de Potência Média - Parque Pedra Grande.

	Metaheurísticas		
	BA	GWO	MVO
Potência Máxima (MW)	319,7467	318,2003	322,2423
Potência Mínima (MW)	318,3873	318,2003	318,2580
Potência Média (MW)	318,4506	318,2003	319,4730
Potência Mediana (MW)	318,3873	318,2003	319,3051
Desvio Padrão	0,1979	0	0,9160
Tempo médio (min.)	59,7235	25,0374	13,1689


Fonte: Elaborado pela autora.

A Figura 29 apresenta a esteira correspondente ao *layout* licenciado no projeto, enquanto a Figura 30 mostra a esteira obtida a partir do *layout* otimizado pelo método MVO, que obteve o melhor desempenho em termos de potência gerada. Nota-se uma redução na intensidade do *wake effect* e na ocorrência de múltiplos fluxos turbulentos, evidenciada pela diminuição das regiões associadas às menores velocidades do vento.

Figura 29 – Esteira de Jensen no *layout* licenciado - Pedra Grande.

Fonte: Elaborado pela autora.

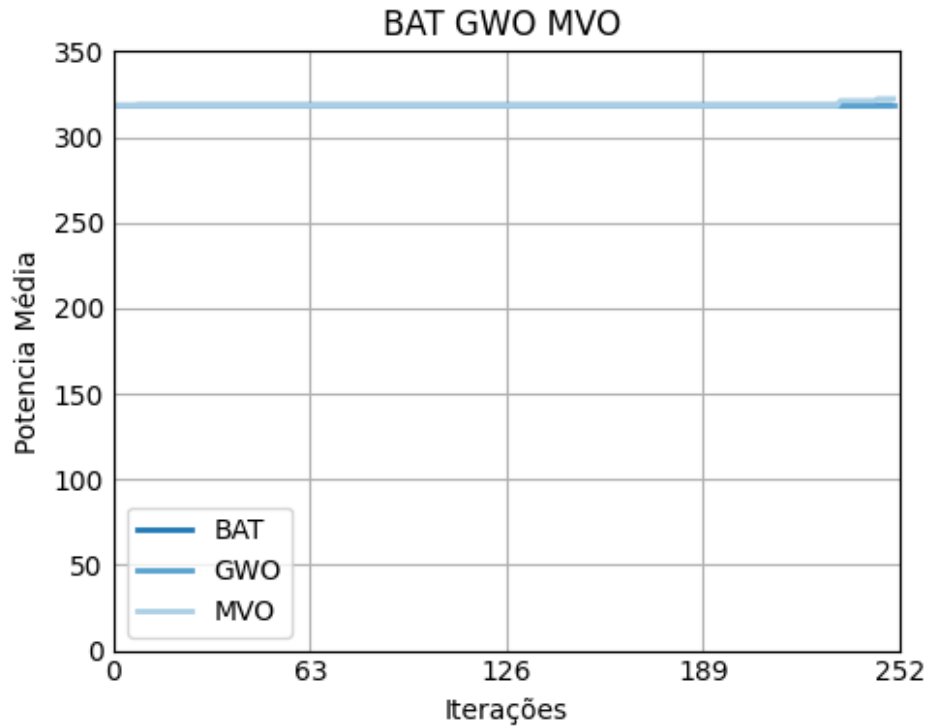
Figura 30 – Esteira de Jensen no *layout* otimizado pelo método MVO - Pedra Grande.



Fonte: Elaborado pela autora.

A Figura 31 apresenta o comportamento de convergência dos algoritmos ao longo das iterações para o Parque Pedra Grande. Observa-se que os valores de potência permanecem praticamente constantes desde as primeiras iterações, indicando que os algoritmos já iniciam o processo com soluções muito próximas do ótimo. O GWO apresenta comportamento completamente estável ao longo de todas as iterações, sem variações perceptíveis. De forma semelhante, o BA e o MVO também exibem pouca variação, com pequenas melhorias apenas nas iterações finais.

Figura 31 – Convergência dos algoritmos - Pedra Grande




Fonte: Elaborado pela autora.

6.2 PARQUE CAMOCIM


Para o segundo estudo de caso, será analisado o parque eólico *offshore* de Camocim, localizado a aproximadamente 6,5 km da costa de Camocim (CE). Este parque foi projetado com 100 aerogeradores distribuídos em uma área de cerca de 570 km². O *layout* inicial do projeto é apresentado na Figura 32. A área retangular é de 53x14 *bits* (742 *bits*), com 43 *bits* restritivos para acomodar o formato disponível do empreendimento. Para determinar a energia extraída por meio do programa, o parque foi incluído conforme mostrado na Figura 33 e potência calculada com esse *layout* foi de 423,5121 MW.

Figura 32 – *Layout* licenciado do Parque Camocim.



Fonte: Elaborado pela autora a partir de (IBAMA, 2025).

Figura 33 – Parque Camocim no Programa desenvolvido.




Fonte: Elaborado pela autora.


6.2.1 Análise 1

Para a simulação com 60% da população alocada no *layout* específico, foram geradas a Figura 34 e a Figura 35, para os parques eólicos otimizados pelos algoritmos BA e MVO, respectivamente. Assim como no Parque Pedra Grande, o algoritmo do GWO não conseguiu obter um *layout* melhor do que o específico. O *layout* ótimo obtido pelo BA teve 25 aerogeradores em posições diferentes, mas adjacentes fisicamente, em relação ao *layout* específico, enquanto o resultado do MVO apresentou 46 posições diferentes, da mesma forma que o BA.

Figura 34 – *Layout* otimizado pelo BA - Análise 1.



Fonte: Elaborado pela autora.

Figura 35 – *Layout* otimizado pelo MVO - Análise 1.


Fonte: Elaborado pela autora.

A Tabela 5 apresenta os resultados obtidos para o Parque Camocim. Observa-se que o método GWO reproduziu exatamente a potência do *layout* licenciado (423,5121 MW), sem apresentar qualquer variação entre as execuções. O algoritmo BA forneceu uma leve melhoria, representando um ganho discreto em relação ao arranjo original. Já o método MVO obteve o melhor desempenho entre as metaheurísticas, alcançando um incremento de até cerca de 1,9 MW em comparação ao *layout* licenciado. As Figuras 36 e 37 apresentam, respectivamente, o *boxplot* da potência obtida e o *boxplot* do tempo de simulação para os três métodos, permitindo visualizar a distribuição das soluções e a variabilidade entre as execuções.

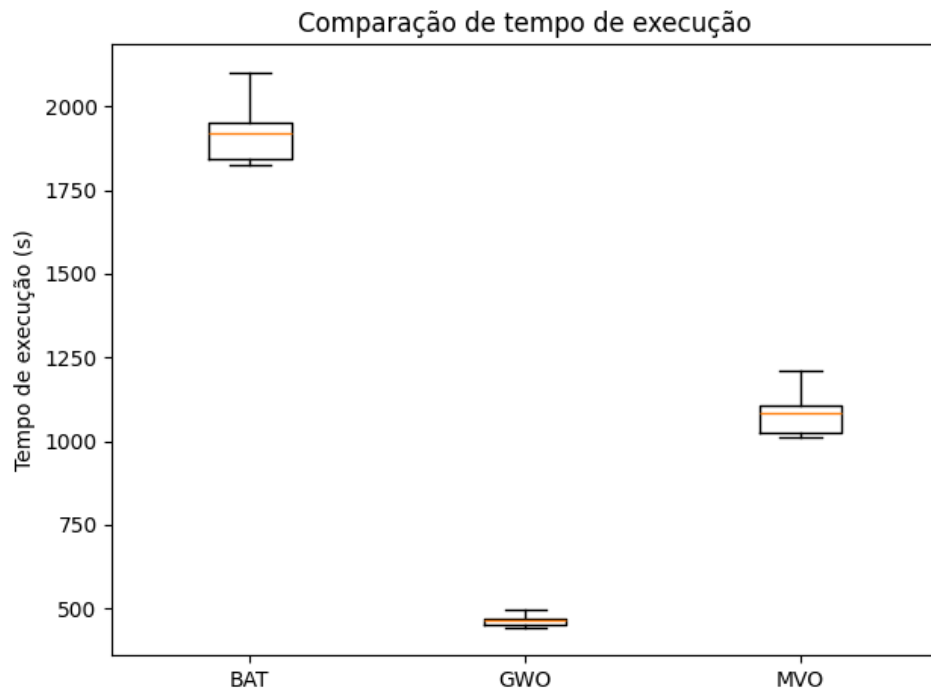
Tabela 5 – Ganho de Potência Média – Parque Camocim – Análise 1.

	Metaheurísticas		
	BA	GWO	MVO
Potência Máxima (MW)	423,8306	423,5121	425,3691
Potência Mínima (MW)	423,8306	423,5121	423,5567
Potência Média (MW)	423,8306	423,5121	424,2364
Potência Mediana (MW)	423,8306	423,5121	424,1361
Desvio Padrão	0	0	0,4443
Tempo médio (min.)	21,3643	7,8099	18,0431

Fonte: Elaborado pela autora.

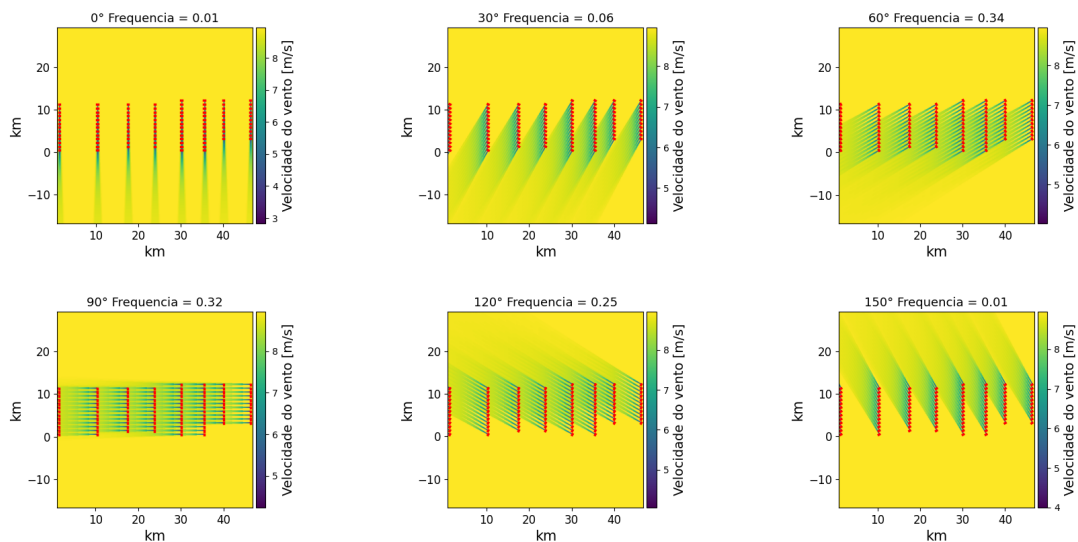
Figura 36 – *Boxplot* da potência - Análise 1.

Fonte: Elaborado pela autora.

Figura 37 – *Boxplot* do tempo - Análise 1.

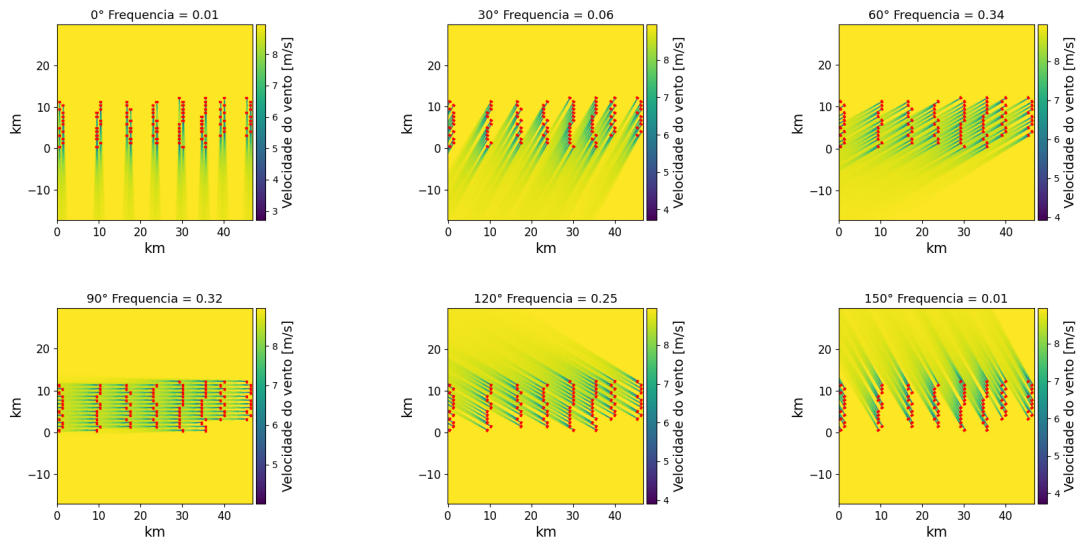
Fonte: Elaborado pela autora.

A Figura 38 apresenta a esteira referente ao *layout* licenciado do Parque Camocim, enquanto a Figura 39 mostra a distribuição de velocidades obtida para o *layout* otimizado pelo método MVO. Observa-se um padrão coerente com o verificado anteriormente no Parque Pedra Grande: o *layout* otimizado tende a suavizar as regiões de baixa velocidade e reduzir a interação entre esteiras.

Figura 38 – Esteira de Jensen no *layout* licenciado - Camocim.

Fonte: Elaborado pela autora.


Figura 39 – Esteira de Jensen no *layout* otimizado pelo método MVO - Camocim.



Fonte: Elaborado pela autora.

A Figura 40 apresenta o comportamento de convergência dos algoritmos para o Parque Camocim. De forma semelhante ao observado no Parque Pedra Grande, os valores de potência mantêm-se praticamente constantes ao longo das iterações, com variações pouco significativas concentradas apenas nas etapas finais do processo. Esse padrão indica que os algoritmos iniciam a busca em regiões já próximas da solução ótima.

Figura 40 – Convergência dos algoritmos - Camocim.




Fonte: Elaborado pela autora.

6.2.2 Análise 2


O comportamento da otimização difere quando a alocação inicial da população dos algoritmos é feita de forma 100% randômica, resultando em comportamentos e *layouts* distintos. A Figura 41 e a Figura 42 mostram os *layouts* ótimos dos algoritmos para essa simulação. Das 50 execuções do algoritmo, o BA obteve 19 soluções factíveis, o GWO não obteve nenhuma e o MVO alcançou 38 soluções factíveis, demonstrando um bom comportamento de busca para o MVO. Os valores obtidos estão apresentados na Tabela 6. Por fim, a Figura 43 apresenta o *boxplot* do tempo de simulação, complementando a avaliação comparativa entre os métodos.

Figura 41 – *Layout* otimizado pelo BA - Análise 2.



Fonte: Elaborado pela autora.

Figura 42 – *Layout* otimizado pelo MVO - Análise 2.

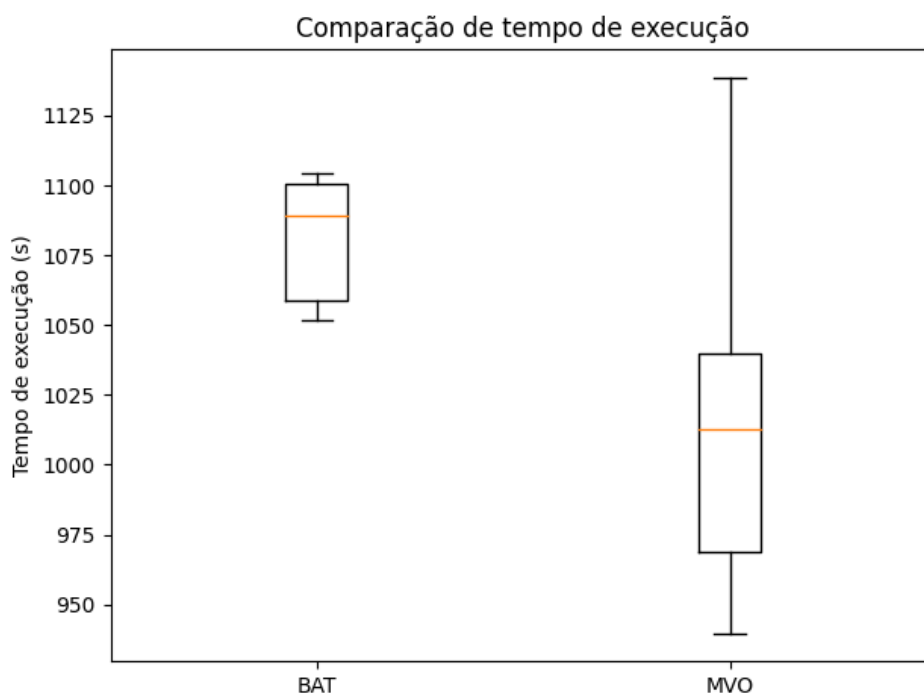


Fonte: Elaborado pela autora.

Tabela 6 – Ganho de Potência Média – Parque Camocim – Análise 2.

	Metaheurísticas	
	BA	MVO
Potência Máxima (MW)	381,6082	394,2903
Potência Mínima (MW)	371,5381	375,7778
Potência Média (MW)	376,3433	383,4083
Potência Mediana (MW)	376,8235	383,5753
Desvio Padrão	2,6618	4,1491
Tempo médio (min.)	18,7152	16,9198

Fonte: Elaborado pela autora.

Figura 43 – *Boxplot* do tempo - Análise 2.

Fonte: Elaborado pela autora.

Ao compararmos o *layout* obtido na análise 1 com o da análise 2, observa-se que na análise 1, a configuração permanece linear e uniforme, semelhante ao *layout* especificado. No entanto, quando a população inicial é randômica, o *layout* otimizado torna-se mais desorganizado e sem padrão. Isso poderia aumentar os custos no sistema coletor do parque, além de comprometer a estética normalmente desejada pelos empreendedores, embora esse

aspecto não tenha sido analisado neste estudo. Portanto, na primeira análise, o algoritmo MVO alcançou uma potência máxima média do parque de 425,3691 MW, cerca de 0,438% superior ao *layout* especificado. Por outro lado, na segunda análise, embora o MVO ainda tenha apresentado melhor desempenho, a potência máxima foi de 394,2903 MW, cerca de 6,9% inferior à obtida na primeira análise. Isso evidencia que ao iniciar com *layouts* já viáveis e desejáveis, os algoritmos conseguem manter a estrutura da configuração e obter melhores resultados do que quando a alocação inicial é randômica.

6.3 DISCUSSÃO DOS RESULTADOS

Os resultados apresentados neste capítulo evidenciam diferenças significativas no comportamento, na robustez e na eficiência das metaheurísticas *Bat Algorithm* (BA), *Grey Wolf Optimizer* (GWO) e *Multiverse Optimizer* (MVO) quando aplicadas ao problema de otimização do *layout* de parques eólicos *offshore*, considerando exclusivamente o modelo de *wake effect* de *Jensen*.

De modo geral, observa-se que a qualidade das soluções obtidas está fortemente associada ao equilíbrio entre exploração e intensificação do espaço de busca, característica intrínseca a cada algoritmo. Essa relação manifesta-se tanto nos valores médios de potência alcançados quanto na variabilidade estatística observada ao longo das execuções.

No Parque Pedra Grande, os resultados indicam que os algoritmos BA e MVO foram capazes de superar a potência média do *layout* licenciado, enquanto o GWO apresentou convergência sistemática para a mesma solução original, sem qualquer variação entre as execuções. Esse comportamento sugere que, para o problema analisado, o GWO mostrou-se excessivamente conservador, com limitação na capacidade de escapar de soluções locais quando inserido em um espaço de busca fortemente restrito pela discretização e pela elevada proporção de bits inviáveis.

O MVO destacou-se por apresentar as maiores potências máximas e médias, embora associado a maior dispersão nos resultados, conforme evidenciado pelos *boxplots*. Essa variabilidade é coerente com o caráter mais exploratório do algoritmo, que amplia a busca por soluções alternativas e, como consequência, aumenta a probabilidade de encontrar arranjos geometricamente mais eficientes do ponto de vista energético. Em contrapartida, o BA apresentou comportamento intermediário, com soluções estáveis e ganhos consistentes, porém inferiores aos máximos alcançados pelo MVO, além de maior custo computacional médio.

A análise visual das esteiras reforça essas conclusões, uma vez que os *layouts* otimizados pelo MVO apresentam redução mais expressiva das regiões de baixa velocidade do vento e menor sobreposição de esteiras, em comparação ao *layout* licenciado. Esse resultado confirma que os ganhos de potência observados estão associados a uma reorganização espacial mais favorável ao escoamento do vento.

No Parque Camocim, comportamento semelhante foi observado. Na Análise 1, em que 60% da população inicial foi alocada no *layout* licenciado, o MVO novamente apresentou o melhor desempenho médio, seguido pelo BA, enquanto o GWO permaneceu incapaz de gerar soluções superiores ao arranjo original. A manutenção de um *layout* inicial viável mostrou-se determinante para a obtenção de soluções energeticamente mais eficientes e geometricamente organizadas.

Por outro lado, a Análise 2, baseada em populações iniciais totalmente aleatórias, revelou limitações adicionais dos algoritmos. O GWO não obteve soluções factíveis, o BA apresentou baixo número de soluções viáveis, e apenas o MVO demonstrou robustez satisfatória, com maior taxa de factibilidade e melhor desempenho médio. Contudo, os *layouts* resultantes nessa condição apresentaram configuração menos uniforme e potencialmente indesejável sob aspectos práticos não avaliados neste estudo, como custo do sistema coletor e complexidade construtiva.

7 CONCLUSÃO

Este trabalho teve como objetivo principal realizar uma análise comparativa do desempenho de três metaheurísticas de otimização global — *Bat Algorithm* (BA), *Grey Wolf Optimizer* (GWO) e *Multiverse Optimizer* (MVO) — aplicadas ao problema de otimização do *layout* de parques eólicos *offshore*, considerando como critério a maximização da potência gerada e a mitigação das perdas associadas ao *wake effect*, modelado exclusivamente pelo modelo de Jensen.

A metodologia foi aplicada a dois parques eólicos *offshore* reais em fase de licenciamento ambiental no Brasil, denominados Pedra Grande e Camocim, permitindo avaliar o comportamento dos algoritmos em cenários distintos e aproximar a análise de condições práticas de planejamento. Os resultados evidenciaram que a escolha da metaheurística influencia diretamente a qualidade das soluções encontradas, a estabilidade estatística das execuções e o custo computacional do processo de otimização.

No Parque Pedra Grande, cujo *layout* licenciado apresentou potência média de 318,20 MW, o algoritmo MVO obteve uma potência média de 319,47 MW, correspondendo a um ganho aproximado de 0,40% em relação ao arranjo original. Embora esse incremento absoluto seja da ordem de 1,27 MW, o resultado demonstra que ajustes espaciais relativamente simples no posicionamento das turbinas podem resultar em melhorias no desempenho energético do parque.

Para o Parque Camocim, na Análise 1, o *layout* licenciado apresentou potência de 423,51 MW, enquanto o MVO alcançou uma potência média de 424,23 MW, representando um ganho aproximado de 0,17% em relação ao *layout* original. Apesar de modesto em termos percentuais, esse resultado confirma a capacidade do MVO de refinar *layouts* previamente bem estruturados, mantendo a geometria geral do parque e reduzindo a interferência entre esteiras.

Na Análise 2 do Parque Camocim, em que a população inicial dos algoritmos foi totalmente randômica, o MVO apresentou potência média de 383,40 MW, valor inferior ao obtido na Análise 1, evidenciando uma redução de desempenho quando comparado a *layouts* iniciais já viáveis. Esse comportamento reforça que a eficácia da otimização está fortemente associada à qualidade da solução inicial, especialmente em problemas com elevado número de restrições espaciais.

De forma geral, os resultados indicam que o MVO apresentou desempenho superior nos dois parques analisados, tanto em termos de potência média quanto de capacidade exploratória, ainda que associado a maior variabilidade estatística. Esse comportamento pode estar relacionado ao seu mecanismo de busca, que combina troca probabilística de variáveis entre soluções e aproximação progressiva da melhor solução encontrada, favorecendo o equilíbrio entre exploração global e refinamento local. Mesmo com ganhos

percentuais relativamente baixos, os incrementos obtidos são relevantes do ponto de vista prático, considerando a escala dos empreendimentos eólicos *offshore* e o impacto acumulado ao longo da vida útil dos parques. O algoritmo GWO demonstrou limitações principalmente na etapa de busca local refinada, resultando em desempenhos inferiores ao esperado para o problema proposto. Observou-se ainda que o algoritmo convergiu repetidamente para o mesmo *layout* nas diferentes execuções realizadas, indicando baixa variabilidade nas soluções encontradas e sugerindo uma possível limitação na exploração de regiões alternativas do espaço de busca. O método BA, embora tenha alcançado melhorias, apresentou tempos de processamento significativamente maiores, cerca de 4,5 vezes superiores ao MVO no caso do Parque Pedra Grande.

É importante ressaltar as limitações do estudo. A utilização exclusiva do modelo de Jensen implica simplificações na representação do *wake effect*, e a análise restringe-se a dois parques e a um conjunto específico de parâmetros para as metaheurísticas. Dessa forma, os resultados não devem ser generalizados para outros cenários ou condições operacionais distintas.

Como trabalhos futuros, recomenda-se a incorporação de modelos de esteira mais complexos, a análise de diferentes regimes de vento e a integração de aspectos adicionais do projeto, como o sistema coletor elétrico e restrições ambientais. Ainda assim, os resultados obtidos demonstram que a aplicação de metaheurísticas, em especial do MVO, constitui uma ferramenta promissora de apoio à decisão no planejamento de parques eólicos *offshore*.

REFERÊNCIAS

- ABEEÓLICA. **Energia Eólica: Os bons ventos do Brasil**. 2025. Disponível em: <https://www.abeeolica.org.br>.
- AMARAL, L.; CASTRO, R. Offshore wind farm layout optimization regarding wake effects and electrical losses. **Engineering Applications of Artificial Intelligence**, v. 60, p. 26–34, 2017.
- AMOUSSOU, I.; ADJAHO, M.; AGBOSSOU, K.; NAPO, K.; FIAGBEDZI, K. The optimal design of a hybrid solar pv/wind/hydrogen/lithium battery for the replacement of a heavy fuel oil thermal power plant. **Sustainability**, MDPI, v. 15, n. 15, p. 11510, 2023. Disponível em: <https://www.mdpi.com/2071-1050/15/15/11510>.
- CABRAL. Otimização de layout e sistema coletor de parques eólicos offshore. In: **Anais do LIII Simpósio Brasileiro de Pesquisa Operacional (SBPO)**. Brasil: [s.n.], 2021. Apresentado no LIII SBPO – Simpósio Brasileiro de Pesquisa Operacional, 2021.
- CABRAL, A. Regime jurídico da energia eólica no brasil: uma discussão sobre autonomia tecnológica e revisão no sistema de leilões. **Revista de Direito Administrativo**, n. 269, p. 225–254, 2015.
- CHAMPEAU, K. « **Wake effect** » : **quel est ce phénomène redoutable pour les parcs éoliens en mer ?** 2024. Acessado em: 19 nov. 2025. Disponível em: <https://www.revolution-energetique.com/actus/wake-effect-quel-est-ce-phenomene-redoutable-pour-les-parcs-eoliens-en-mer/>.
- DORIGO, M. **Optimization, Learning and Natural Algorithms**. Tese (Tese (Doutorado em Ciência da Computação)) — Politecnico di Milano, Milão, Itália, 1992.
- EPE, E. de P. E. **Balço Energético Nacional 2025**. Rio de Janeiro: [s.n.], 2025. Disponível em: https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-885/topico-767/BEN_S%C3%ADntese_2025_PT.pdf.
- FERREIRA, F. **Ponderações essenciais sobre o marco regulatório das eólicas offshore**. 2023.
- GAUMOND, M. *et al.* Benchmarking of wind turbine wake models in large offshore windfarms. In: **The Science of Making Torque from Wind 2012: 4th Scientific Conference**. [S.l.: s.n.], 2012.
- Global Wind Atlas. **Global Wind Atlas**. 2025. Acesso em: 01 nov. 2025. Disponível em: <https://globalwindatlas.info/en/>.
- GOMES, L. R.; MARCHI, C. H. Do moinho de vento à turbina hidrocínética. In: **Anais do XLV Congresso Brasileiro de Educação em Engenharia (COBENGE)**. Joinville, SC: UDESC / UNISOCIESC, 2017. p. 1–10. Disponível em: <https://www.abenge.org.br/cobenge/arquivos/2017/artigos/>.
- GWEC, G. W. E. C. **Global Wind Report 2025**. Bruxelas: [s.n.], 2025. Disponível em: <https://26973329.fs1.hubspotusercontent-eu1.net/hubfs/26973329/2.%20Reports/Global%20Wind%20Report/GWEC%20Global%20Wind%20Report%202025.pdf>.

- HASSOINE, M. A. *et al.* Improved evaluation of the wind power potential of a large offshore wind farm using four analytical wake models. **International Journal of Renewable Energy Development**, v. 11, n. 1, 2022.
- HENRY, J. **Os primeiros geradores eólicos caseiros do mundo**. 2018. Blogspot. Disponível em: <https://meioseculodeaprendizagens.blogspot.com/2018/05/os-primeiros-geradores-eolicos-caseiros.html>.
- HOLLAND, J. Genetic algorithms. **Scientific American**, v. 267, n. 1, p. 44–50, 1992.
- IBAMA. **Complexos eólicos offshore: Projetos com processos de licenciamento ambiental abertos no IBAMA**. 2025. Atualização em: 11 março 2025. Disponível em: <https://www.gov.br/ibama/pt-br/assuntos/laf/consultas/arquivos/>.
- IRENA, I. R. E. A. **Renewable Energy Benefits: Leveraging Local Capacity for Offshore Wind**. Abu Dhabi, 2018. Disponível em: <https://www.irena.org/publications/2018/May/Leveraging-Local-Capacity-for-Offshore-Wind>.
- JENSEN, N. O. **A note on wind generator interaction**. [S.l.], 1983.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: **Proceedings of IEEE International Conference on Neural Networks**. [S.l.: s.n.], 1995. IV, p. 1942–1948.
- LI, L.; WANG, Y.-m.; LIU, Y.-q. **Impact of wake effect on wind power prediction**. 2013.
- MIRJALILI, S.; MIRJALILI, S. M.; LEWIS, A. Grey wolf optimizer. **Advances in Engineering Software**, v. 69, p. 46–61, 2014.
- MIRJALILI, S.; MIRJALILI, S. Z.; HATAMLOU, A. Multi-verse optimizer: A nature-inspired algorithm for global optimization. **Neural Computing and Applications**, Springer, v. 27, p. 495–513, 2016.
- OLIVIERI, B. P. **Otimização do Projeto de Pontes Protendidas Pré Moldadas pelo Método dos Algoritmos Genéticos**. Dissertação (Dissertação (Mestrado)) — Universidade Federal do Rio de Janeiro, COPPE, Rio de Janeiro, 2004.
- ONS, O. N. do S. E. **Boletim Geração Eólica**. 2025. Disponível em: <https://www.ons.org.br/Paginas/resultados-da-operacao/boletim-geracao-eolica.aspx>.
- PEREIRA, M. V. d. R. **Impacto da altura de aerogeradores sobre a velocidade do vento, energia, efeito de esteira e intensidade de turbulência: Estudos de caso em três projetos eólicos localizados no Brasil**. Dissertação (Mestrado) — Instituição não informada, Brasil, 2016.
- PILLAI, A. C.; GOUNDAR, N. Y. A.; KÜHN, A. J.; LARSEN, M. G. R. C.; HANSEN, K. S. Application of an offshore wind farm layout optimization methodology at middelgrunden wind farm. **Ocean Engineering**, v. 139, p. 287–297, 2017.
- PINTO, M. O. **Fundamentos de Energia Eólica**. [S.l.], 2013.
- Poul la Cour Museet. **Poul la Cour**. 2025. Site institucional do Poul la Cour Museet. Disponível em: <https://www.poullacour.dk/en/film-about-poul-la-cour/>.

RAMLI, M. A. M.; BOUCHEKARA, H. R. E. H. Wind farm layout optimization considering obstacles using a binary most valuable player algorithm. **IEEE Access**, IEEE, v. 8, p. 131553–131564, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/91394777>.

SHIN, J.; BAEK, S.; RHEE, Y. Wind farm layout optimization using a metamodel and ea/psa algorithm in korea offshore. **Energies**, MDPI, v. 14, n. 1, p. 146, 2020. Open access. Disponível em: <https://www.mdpi.com/1996-1073/14/1/146>.

TEGNER, M.; MCMILLAN, D.; DAHLHAUG, O. G.; STEWART, T. J. A comprehensive cost-based optimization framework for offshore wind farm layouts. **Renewable Energy**, v. 120, p. 149–161, 2018. Disponível em: <https://doi.org/10.1016/j.renene.2017.12.066>.

TESSMER, H. **Uma síntese histórica da evolução do consumo de energia pelo homem**. 2023. Disponível em: <https://revista.liberato.com.br/index.php/revista/article/view/43>.

TIMES, T. **Iran moves closer to UNESCO recognition of windmills**. 2024. Disponível em: <https://www.tehrantimes.com>.

VAICBERG, H.; VALIATT, G.; FERREIRA, M. Energia eólica offshore: Um overview do cenário global e o contexto brasileiro. **Revista de Direito e Negócios Internacionais da Maritime Law Academy – International Law and Business Review**, v. 1, n. 1, p. 114–143, 2021.

YANG, X.-S. A new metaheuristic bat-inspired algorithm. In: **Nature Inspired Cooperative Strategies for Optimization (NICSO 2010)**. [S.l.]: Springer, 2010. p. 65–74.