



UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
MESTRADO PROFISSIONAL EM ENERGIA E AMBIENTE

ALAN PENHA DE JESUS

**DESPACHO ECONÔMICO E AMBIENTAL EM SISTEMAS DE POTÊNCIA COM
INSERÇÃO DE GERAÇÃO EÓLICA UTILIZANDO ALGORITMOS QUÂNTICOS**

São Luís

2024

ALAN PENHA DE JESUS

**DESPACHO ECONÔMICO E AMBIENTAL EM SISTEMAS DE POTÊNCIA COM
INSERÇÃO DE GERAÇÃO EÓLICA UTILIZANDO ALGORITMOS QUÂNTICOS**

Dissertação de Mestrado submetida à Coordenação do Programa de Pós-Graduação em Energia e Ambiente da Universidade Federal do Maranhão (UFMA), como parte dos requisitos para obtenção do título de Mestre em Energia e Ambiente.

Orientador: Prof. Dr. Paulo Henrique da Silva Leite Coelho.

Coorientador: Prof. Dr. Raimundo Nonato Diniz Costa Filho.

São Luís

2024

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Jesus, Alan Penha de.

Despacho econômico e ambiental em sistemas de potência utilizando algoritmos quântico / Alan penha de Jesus. - 2024.

70 f.

Coorientador(a) 1: Raimundo Nonato Diniz Costa Filho.

Orientador(a): Paulo Henrique da Silva Leite Coelho.

Dissertação (Mestrado) - Programa de Pós-graduação em Energia e Ambiente/CCET, Universidade Federal do Maranhão, São Luis - Ma, 2024.

1. Despacho econômico e ambiental. 2. Meta-heurísticas. 3. Energia eólica. 4. Otimização. 5. . I. Costa Filho, Raimundo Nonato Diniz. II. Leite Coelho, Paulo Henrique da Silva. III. Título.

ALAN PENHA DE JESUS

**DESPACHO ECONÔMICO E AMBIENTAL EM SISTEMAS DE POTÊNCIA COM
INSERÇÃO DE GERAÇÃO EÓLICA UTILIZANDO ALGORITMOS QUÂNTICOS**

Dissertação de Mestrado submetida à Coordenação do Programa de Pós-Graduação em Energia e Ambiente da Universidade Federal do Maranhão (UFMA), como parte dos requisitos para obtenção do título de Mestre em Energia e Ambiente.

Aprovado em: ____/____/____

BANCA EXAMINADORA

Prof. Dr. Paulo Henrique da Silva Leite Coelho (Orientador)

Universidade Federal do Maranhão – UFMA

Prof. Dr. Raimundo Nonato Diniz Costa Filho (Coorientador)

Universidade Federal do Maranhão – UFMA

Prof. Dr. Jaiver Efren Jaimes Figueroa (Membro da Banca)

Universidade Federal do Maranhão – UFMA

Prof. Dr. Antonio Adolpho Martins Raposo (Membro da Banca)

Instituto Federal de São Paulo – IFSP

Dedico este trabalho a todos que contribuíram de alguma forma para a sua conclusão.

AGRADECIMENTOS

A Deus, por ter me dado o dom da vida e permitido que eu chegasse até aqui.

Aos meus filhos, Victor e Maria Victoria, que são a razão da minha vida e combustível para seguir sempre em frente.

Aos meus pais, Afonso Bispo e Valdinez Penha, por se dedicarem à educação dos filhos e não medirem esforços para nos proporcionar bem-estar. Obrigado por sempre estarem incansavelmente me incentivando nos meus objetivos de vida.

À minha esposa, Grasy, pois nunca me permitiu desistir. Por ter sido o meu apoio nos momentos mais difíceis, pelas escutas e orientações.

À minha madrinha, Maria da Graça, pela preocupação e incentivo constante no meu desenvolvimento acadêmico e profissional.

Aos professores, Paulo Coelho e Raimundo Diniz, pela paciência, escutas e orientações que foram determinantes para a conclusão deste trabalho.

Aos professores, Jaiver e Antônio Adolpho, por aceitarem fazer parte desta banca e contribuírem com o trabalho.

Aos meus amigos, Áviner, Dudu e Sânia, pelas conversas, companheirismo e torcida.

A Dona Isabel, por ajudar nos cuidados aos pequenos durante a elaboração deste trabalho.

A todos os familiares e amigos que de certa forma contribuíram direta ou indiretamente para que pudesse concluir este trabalho.

“Não me sinto obrigado a acreditar que o mesmo Deus que nos dotou de sentidos, razão e intelecto, pretenda que não os utilizemos”.

(Galileu Galilei).

RESUMO

Este trabalho aborda sobre o despacho econômico ambiental como um problema de otimização multiobjetivo. Para resolver este problema explorou-se o potencial de meta-heurísticas quânticas, incluindo o *Quantum Grey Wolf Optimizer* (QGWO), o *Quantum Particle Swarm Optimizer* (QPSO) e o *Quantum Flower Pollination Algorithm* (QFPA), que são métodos avançados inspirados em processos naturais para buscar soluções eficientes, visando comparar o desempenho e a adequação dos algoritmos. Os experimentos foram conduzidos em dois sistemas de teste do *Institute of Electrical and Electronic Engineers* (IEEE), sendo um sistema com seis unidades e outro com 14 unidades geradoras. Ambos os sistemas foram analisados considerando diferentes cenários de carga. Adicionalmente, explorou-se cenários com a inserção de energia eólica, modelada pela distribuição de *Weibull*, para capturar a natureza estocástica do vento. Os resultados obtidos evidenciaram que o QFPA se destacou em relação às outras meta-heurísticas avaliadas, fornecendo soluções de maior qualidade, tendo como base os mínimos, médios e desvios padrão do custo econômico de geração, com redução de até 5,6% para custo econômico mínimo, e 32,9% para custo ambiental mínimo, para o problema de despacho econômico ambiental solucionado para os sistemas testes. Isso sugere que o QFPA pode ser a escolha preferencial para resolver desafios similares em sistemas de energia elétrica, especialmente quando se considera a integração de fontes renováveis, como a energia eólica, no processo de otimização.

Palavras-chave: despacho econômico e ambiental; meta-heurísticas; energia eólica; otimização.

ABSTRACT

This work addresses environmental economic dispatch as a multi-objective optimization problem. To solve this problem, the potential of quantum meta-heuristics was explored, including the Quantum Grey Wolf Optimizer (QGWO), the Quantum Particle Swarm Optimizer (QPSO), and the Quantum Flower Pollination Algorithm (QFPA), which are advanced methods inspired by natural processes to seek efficient solutions, aiming to compare the performance and suitability of these algorithms. The experiments were conducted on two test systems from the Institute of Electrical and Electronics Engineers (IEEE), one with six units and another with 14 generating units. Both systems were analyzed considering different load scenarios. Additionally, scenarios with the integration of wind energy, modeled by the Weibull distribution to capture the stochastic nature of the wind, were explored. The results showed that QFPA outperformed the other evaluated meta-heuristics, providing higher quality solutions based on the minimum, average, and standard deviations of the economic generation cost, with reductions of up to 5.6% for the minimum economic cost, and 32.9% for the minimum environmental cost, for the environmental economic dispatch problem solved for the test systems. This suggests that QFPA could be the preferred choice for solving similar challenges in electrical power systems, especially when considering the integration of renewable sources, such as wind energy, in the optimization process.

Keywords: economic and environmental dispatch; metaheuristic; wind power; optimization.

LISTA DE FIGURAS

Figura 1 – Representação esquemática da fronteira de Pareto	28
Figura 2 – Representação hierárquica dos lobos cinzentos	39
Figura 3 – Comportamento da convergência das meta-heurísticas para Cenários 1 e 2	50
Figura 4 – Box Plot da solução (Cenários 1 e 2)	51
Figura 5 – Comportamento da convergência das meta-heurísticas (Cenários 3 e 4)	53
Figura 6 – Box Plot da solução (Cenários 3 e 4)	53
Figura 7 – Comportamento da convergência das meta-heurísticas (Cenários 5 e 6)	55
Figura 8 – Box Plot da solução (Cenários 5 e 6)	55
Figura 9 – Comportamento da convergência das meta-heurísticas (Cenários 7 e 8)	57
Figura 10 – Box Plot da solução (Cenários 7 e 8)	57
Figura 11 – Comparativo de curva de Fronteira de Pareto QFPA	64

LISTA DE TABELAS

Tabela 1 – Coeficientes de custo e ambiental do sistema de seis geradores	47
Tabela 2 – Limites operativos das unidades geradoras do sistema de seis geradores	47
Tabela 3 – Matriz de Perdas Bij.	47
Tabela 4 – Parâmetros da usina eólica.....	48
Tabela 5 – Coeficientes de custo e ambiental do sistema de 14 geradores	48
Tabela 6 – Limites operativos das unidades geradoras do sistema de 14 geradores	49
Tabela 7 – Resultados da simulação dos Cenários 1 e 2	50
Tabela 8 – Comparativo valores do Box Plot (Cenários 1 e 2).....	51
Tabela 9 – Resultados da simulação dos Cenários 3 e 4	52
Tabela 10 – Comparativo dos valores do Box Plot (Cenários 3 e 4)	54
Tabela 11 – Resultados da simulação dos Cenários 5 e 6	54
Tabela 12 – Comparativo valores do Box Plot (Cenários 5 e 6).....	56
Tabela 13 – Resultados da simulação dos Cenários 7 e 8	56
Tabela 14 – Comparativo valores do Box Plot (Cenários 7 e 8).....	58
Tabela 15 – Panorama comparativo de resultados dos Cenários.....	63

LISTA DE ILUSTRAÇÕES

Gráfico 1 – Matriz de Produção de Energia Elétrica.....	16
Imagem 1 – Lobos cinzentos atacando presa	39

LISTA DE QUADROS

Quadro 1 – Pseudocódigo do PSO	36
Quadro 2 – Pseudocódigo do QPSO	38
Quadro 3 – Pseudocódigo do GWO	41
Quadro 4 – Pseudocódigo do QGWO	42
Quadro 5 – Pseudocódigo do FPA	44
Quadro 6 – Pseudocódigo do QFPA	45

LISTA DE SIGLAS E ABREVIATURAS

BCGA	Algoritmo Genético Codificado Binário
DE	Despacho Econômico
DEA	Despacho Econômico Ambiental
EBDR	Estudo Básico de Desenvolvimento Regional
FDC	Função de Distribuição Cumulativa
FDP	Função de Distribuição de Probabilidade
FPA	Otimização por Polinização das Flores
GABC	Algoritmo de Colônia de Abelhas Artificial Guiada Gbest
GWO	<i>Grey Wolf Optimizer</i>
IEA	<i>International Energy Agency</i> /Agência Internacional de Energia
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
IHS	Busca de Harmonia Aprimorada
MG	Microgeração
MMOCE	Algoritmo de Entropia Cruzada Multiobjetivo Modificado
MOEA/D	Algoritmo Evolutivo Multiobjetivo Baseado em Decomposição
MOPSO	Algoritmo de Otimização de Enxame de Partículas Multiobjetivo
MPSO	Algoritmo de Otimização de Enxame de Partículas Modificado
PSO	Otimização de Enxame de Partículas
QFPA	<i>Quantum Flower Polination Algorithm</i>
QGWO	<i>Quantum Grey Wolf Optimizer</i>
QPSO	<i>Quantum Particle Swarm Optimizer</i>
SMODE	<i>Summation Based Multi-Objective Differential Evolution</i> /Algoritmo de Evolução Diferencial Multiobjetivo
WU-ABC	Algoritmo de Atualização de Ponderação Artificial de Colônia de Abelhas

SUMÁRIO

1 INTRODUÇÃO	15
1.1 Generalidades	15
1.2 Formulação do problema	17
1.3 Objetivos	18
<i>1.3.1 Objetivo geral</i>	18
<i>1.3.2 Objetivos específicos</i>	19
1.4 Justificativa	19
1.5 Metodologia	19
1.6 Referencial Teórico	20
1.7 Organização do trabalho	22
2 DESPACHO ECONÔMICO E AMBIENTAL	24
2.1 Despacho Econômico de energia	24
2.2 Despacho Econômico e Ambiental	25
2.3 Curva de Pareto	27
2.4 Integração da energia eólica ao problema multiobjetivo	29
<i>2.4.1 Modelo da energia eólica no DEA</i>	29
<i>2.4.2 Formulação do problema DEA com energia eólica</i>	31
3 META-HEURÍSTICAS QUÂNTICAS	34
3.1 Otimização por Enxame de Partículas (PSO e QPSO)	34
<i>3.1.1 Otimização de Enxame de Partículas</i>	34
<i>3.1.2 Quantum Particle Swarm Optimizer</i>	36
3.2 Otimização do Lobo Cinzento (GWO e QGWO)	38
<i>3.2.1 Grey Wolf Optimizer</i>	38
<i>3.2.2 Quantum Gray Wolf Optimization</i>	41
3.3 Otimização da Polinização das flores (FPA e QFPA)	42
<i>3.3.1 Algoritmo de Otimização de Polinização das Flores</i>	42
<i>3.3.2 Quantum Flower Polination Algorithm</i>	44
4 SIMULAÇÕES, RESULTADOS E DISCUSSÃO	46
4.1 Sistemas-teste e representação da energia eólica	46
<i>4.1.1 Sistema de seis unidades geradoras</i>	46
<i>4.1.2 Sistema de 14 unidades geradoras</i>	48
4.2 Simulações e resultados	49

4.2.1 Solução do DEA sem energia eólica – Sistema seis geradores	49
4.2.2 Solução do DEA com energia eólica – Sistema seis geradores	52
4.2.3 Solução do DEA sem energia eólica – Sistema 14 geradores	54
4.2.4 Solução do DEA com energia eólica – Sistema 14 geradores	56
4.3 Discussão dos resultados	58
4.4 Análise da Curva de ParetoPareto	63
5 CONCLUSÃO E SUGESTÃO DE TRABALHOS FUTUROS	65
REFERÊNCIAS	66

1 INTRODUÇÃO

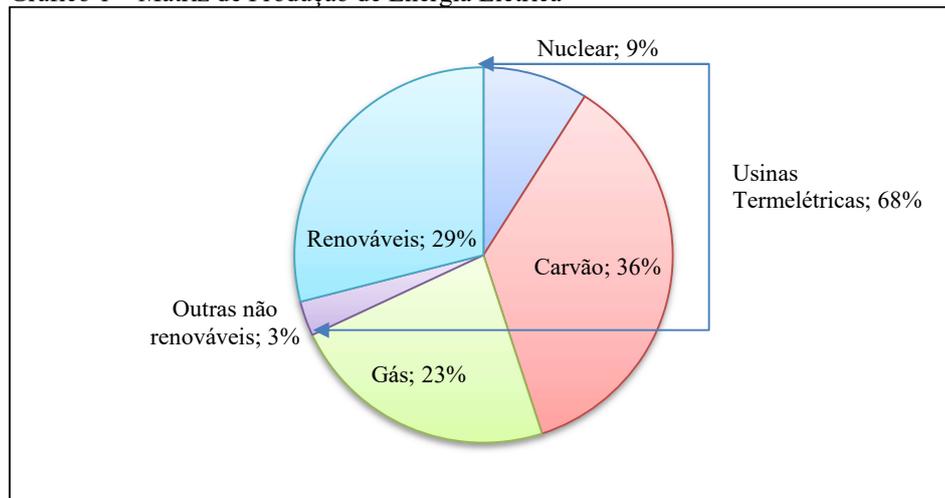
1.1 Generalidades

A facilidade com que a energia elétrica pode ser transformada em outras formas de energia – luminosa, mecânica, térmica, sonora – rapidamente e sem poluição, levou a humanidade a uma gigantesca utilização desta forma de energia, a tal ponto que atualmente a energia elétrica é considerada vital para o desenvolvimento de qualquer país. Para levar a energia elétrica a todos os consumidores, grandes usinas, utilizando as mais variadas formas de força motriz – hidráulica, térmica, atômica, eólicas e solares – são interligadas entre si e às subestações dos grandes centros de carga por meio de longas linhas de transmissão em altas e extra-altas tensões, formando gigantescas redes de transmissão que, juntamente com as linhas e subestações de subtransmissão e de distribuição, formam os sistemas elétricos de potência (SEP) (Bichels, 2019).

Com a crescente demanda por eletricidade impulsionada pelo desenvolvimento industrial, descobrir novas fontes de energia disponível – que visem converter a energia de uma forma consciente, preservando a biosfera – é um dos maiores desafios enfrentados pelo mundo atual, e que demandam inovação e abordagens sustentáveis (Stevenson Jr., 1986). Os desafios são mais complexos quando essa energia tem que ser entregue ao consumidor com: menor custo, maior continuidade, maior conformidade e máxima segurança, o que são os objetivos dos operadores e planejadores do sistema elétrico de potência.

De acordo com a *International Energy Agency*/Agência Internacional de Energia (IEA, 2023), a produção de energia elétrica para atender à demanda mundial foi de 28.642 TWh, tal montante foi responsável por gerar uma emissão de poluentes na ordem de 13.207 Mt CO₂. Cabe destacar que a matriz de produção de energia elétrica mundial, apresentada na Figura 1, revela que 68% do total produzido é oriundo de usinas termelétricas, aquelas que geram energia através da queima de combustíveis fósseis, que são: carvão, gás natural e urânio (nuclear).

Gráfico 1 – Matriz de Produção de Energia Elétrica



Fonte: adaptado de IEA (2023).

Os combustíveis fósseis estão na origem de grandes catástrofes ambientais e alterações climáticas, além de representarem custos elevados. São estes aspectos que têm suscitado uma aposta na promoção da produção de energia elétrica com base em fontes de energia renovável, em detrimento de fontes que promovam a emissão de gases nocivos ao meio ambiente (Rocha, 2010).

As energias renováveis contribuíram, em 2022, com 29% na produção total de energia, e a estimativa da IEA é de que até 2025 as fontes renováveis cresçam em 9%. Apesar desse crescimento vertiginoso, o Planeta ainda depende fortemente das usinas termelétricas e combustíveis fósseis, visto que para 2025, espera-se que 63% da matriz ainda sejam de fontes termelétricas (IEA, 2023).

Esta aposta na produção de energia, a partir das energias renováveis, resulta num agravamento da incerteza associada à previsão de Cenários de geração, uma vez que estas energias dependem de fatores climáticos, como a disponibilidade do vento.

O setor elétrico tem sentido nos últimos anos uma rápida evolução, com o surgimento de mercados livres, com o crescente aumento da integração da geração distribuída, com o aumento do consumo, exigências regulatórias de confiabilidade e sustentabilidade, aumento do preço do petróleo etc. Tudo isso tornou a operação e manutenção do sistema elétrico muito complexa, resultando em uma extrema preocupação por partes dos operadores e planejadores, fazendo com que a redução dos custos de operação do sistema e, conseqüentemente, a redução dos custos do despacho, seja cada vez mais uma prioridade (Rocha, 2010).

Os custos associados à geração de energia e operação do sistema elétrico têm sido historicamente um fator determinante na tomada de decisões, buscando-se um equilíbrio entre

a oferta e a demanda. Por isso, é imperativo encontrar soluções eficientes que atendam não apenas aos requisitos operacionais e econômicos do sistema elétrico, mas também que abordem as crescentes preocupações ambientais relacionadas com as emissões de poluentes.

O Despacho Econômico (DE) de energia emerge como um tema de extrema relevância no contexto contemporâneo da operação de sistemas elétricos. A crescente complexidade desse ambiente, impulsionada por uma série de fatores, torna imperativa a formulação e investigação de problemas que visem otimizar a alocação de recursos energéticos.

1.2 Formulação do problema

O clássico problema do DE de energia elétrica envolve a redução de custo operacional de geração, garantindo o suprimento de eletricidade para a população. Essa problemática sofreu uma sutil transformação à medida que a população se tornou cada vez mais preocupada com as questões ambientais e as exigências regulatórias mais rigorosas. Desse modo, o DE começou a considerar o despacho de geração para minimizar a emissão de poluentes e conservar várias formas de combustível, garantindo custos mínimos de operação (Wood; Wollenberg, 1996).

Desta forma, a resolução de um problema de Despacho Econômico Ambiental (DEA) visa encontrar um ponto ótimo de operação das gerações térmicas com o menor custo de operação e com a menor emissão de poluentes possível, visando a segurança energética do sistema. Por isso, a problemática é chamada de *multiobjetivo*, tendo dois pontos focais a serem alcançados: reduzir custo de operação e a emissão de poluentes, os quais são objetivos incomensuráveis e contraditórios.

Por outro lado, as energias renováveis, como, por exemplo, a energia eólica, que tem sido cada vez mais utilizada e integrada ao sistema de potência, contribui com um grande ganho de economia, ou seja, reduzindo o custo de geração. No entanto, devido às incertezas da potência e velocidade vento, inerentes à sua natureza, a inserção da energia eólica torna difícil a determinação da solução ótima do DEA (Li *et al.*, 2017).

No DEA, as características não lineares dos geradores de energia, e suas restrições operacionais são consideradas como: capacidade limite de geração das limitações de geração, limites de taxa de rampa, zonas de operação proibidas e perda de transmissão (Kuo, 2010). Tais restrições tornam o problema mais complexo, exigindo métodos de soluções matemáticas variados e ferramentas computacionais.

Uma das técnicas são os algoritmos meta-heurísticos, ou seja, métodos de otimização projetados de acordo com as estratégias estabelecidas em uma estrutura meta-heurística. Como

o nome sugere, são sempre de natureza heurística, fato que os distingue dos métodos exatos, que vêm com uma prova de que a solução ótima será encontrada em um tempo finito. As meta-heurísticas são, portanto, desenvolvidas especificamente para encontrar uma solução que seja “boa o suficiente” em um tempo de computação “pequeno o suficiente”.

Os fundamentos subjacentes de diferentes meta-heurísticas variam significativamente. Alguns são modelados baseados no processo de otimização, usando uma metáfora aparentemente não relacionada com a otimização, como a evolução natural (algoritmos genéticos/evolutivos), o resfriamento de um sólido cristalino (recozimento simulado) ou o comportamento de enxames de animais, como colônia de formigas, abelhas, morcegos, lobos etc. Tudo isso em busca de explorar a estrutura do problema para melhorar a busca por boas soluções (Glover; Sörensen, 2015).

Nas últimas décadas, as meta-heurísticas foram melhoradas com a implementação dos princípios físicos da mecânica quântica, e passaram a ser chamadas de *algoritmos quânticos*. A proposta neste trabalho é solucionar o problema de DEA através de três meta-heurísticas quânticas que serão implementadas separadamente, a saber: Otimização através de nuvem de partículas quânticas/*Quantum Particle Swarm Optimization* (QPSO); Algoritmo quântico baseado na polinização das flores/*Quantum Flowers Pollination Algorithm* (QFPA); Otimização através do comportamento quântico de Lobos Cinzentos/*Quantum Grey Wolf Optimization* (QGWO).

São utilizados sistemas-teste do *Institute of Electrical and Electronic Engineers* (IEEE) com acréscimo de uma usina eólica. Para a usina eólica, são utilizados parâmetros predefinidos, tomando como base condições reais de vento, obtidas através de base de dados. Espera-se obter resultados bem próximos, mas com desempenhos diferentes. Almeja-se, ainda, uma contribuição significativa da injeção de energia proveniente de fonte eólica no que diz respeito à redução de emissão de gases nocivos ao meio ambiente.

1.3 Objetivos

1.3.1 Objetivo geral

Solucionar o problema DEA em sistemas testes, sendo um de 6 geradores e outro de 14 geradores, com a inserção de energia renovável (eólica), utilizando técnicas meta-heurísticas quânticas bioinspiradas.

1.3.2 Objetivos específicos

- Implementar o desenvolvimento e técnicas de algoritmos quânticos da literatura, como o QGWO, QPSO e QFPA;
- Comparar a efetividade e o desempenho dos algoritmos quânticos propostos na solução do problema DEA com a inserção de usina eólica, avaliando-os em sistemas testes com diferentes cenários de carga;
- Analisar a contribuição da geração eólica no DEA para os sistemas testes;

1.4 Justificativa

A justificativa para esta pesquisa reside na necessidade de aprimorar as práticas de despacho em sistemas elétricos modernos, alinhando-as com objetivos econômicos e ambientais. A inserção de energia eólica destaca a importância de métodos avançados, como algoritmos quânticos, na busca por soluções ótimas que considerem a dinâmica do ambiente e as expectativas crescentes em relação à sustentabilidade. Essa formulação do problema proporciona uma estrutura sólida para investigar o despacho econômico e ambiental em sistemas elétricos com a presença de energia eólica, explorando o potencial revolucionário dos algoritmos quânticos nesse contexto.

1.5 Metodologia

Para o desenvolvimento deste trabalho de pesquisa, realiza-se uma revisão de literatura, onde faz-se um levantamento de estudos científicos acerca do DEA, e também métodos matemáticos computacionais (algoritmos quânticos) utilizados para a solução do problema. O escopo consiste em trabalhar com três métodos quânticos, com a implementação de otimizações na solução do DEA. Paralelo a isso, no DEA acrescenta-se contribuições do despacho de uma usina eólica, com a proposta de modelagem dessa usina com a tentativa de representar a imprevisibilidade do vento.

A implementação dos algoritmos, a modelagem da usina eólica e a resolução do problema ocorre através do *software* MatLab (MATLAB, 2022). Utiliza-se também de dois sistemas elétricos testes do IEEE com características de pequeno e médio porte, respectivamente. Após a realização das implementações e da modelagem da usina eólica, faz-

se a simulação do problema DEA nos sistemas-teste mencionados acima. Em seguida, os resultados são comparados no tocante ao desempenho de cada método, sendo avaliada a contribuição da usina eólica para a redução de emissão de poluentes e gastos com geração. Para a apresentação didática dos resultados, utiliza-se métodos estatísticos, como o gráfico de Pareto, Box Plot e afins.

1.6 Referencial Teórico

O DEA é resolvido utilizando um algoritmo baseado na otimização de enxame de partículas quânticas de evolução genética (DE-CQPSO), cujo objetivo é obter rápida convergência (Xin-Gang *et al.*, 2020). O resultado é comparado com outro algoritmo, o QPSO. O DE-CQPSO tem um melhor desempenho tanto para problemas de objetivos simples, quanto para problemas multiobjetivos, como é o caso do DEA.

O *Summation Based Multi-Objective Differential Evolution*/Algoritmo de Evolução Diferencial Multiobjetivo (SMODE) é usado em Qu (2016) para otimizar a economia no problema de despacho de emissões de geração com a inserção da energia eólica estocástica. A função de distribuição de probabilidade *Weibull* é usada para modelar a natureza estocástica da energia eólica e a incerteza é tratada como uma restrição do sistema.

Já em Jadhav e Roy (2013), também se usa a função de distribuição de Weibull para modelar a característica aleatória dos ventos. A solução do problema DEA, com a inserção de energia eólica no sistema, é otimizada através do Algoritmo de Colônia de Abelhas Artificial Guiada Gbest (GABC).

Segundo Yao (2012), Zhu (2014) e Niu (2021) técnicas de otimização foram desenvolvidas, como: QPSO, Algoritmo Evolutivo Multiobjetivo baseado em Decomposição (MOEA/D) e um Algoritmo de Entropia Cruzada Multiobjetivo Modificado (MMOCE), respectivamente. Foram aplicados, para otimizar o custo e emissão do sistema elétrico, compostos por fontes térmicas e eólicas. As fontes eólicas foram modeladas pela distribuição de *Weibull*, a fim de representar a variável aleatória do vento.

Elattar (2019) solucionou o problema do DEA em vários sistemas, com a inserção de energias renováveis (eólicas e solar), utilizando o algoritmo *Shuffle Frog Jumping* otimizado. A modelagem da energia renovável, tanto solar quanto eólica, foi feita de forma simplista, considerando apenas as cargas negativas e reduzindo a demanda total do sistema em determinados horários.

Em resolução do problema do DEA, outros autores trabalharam com um sistema de microrredes, considerando a modelagem imprevisível e aleatória dos ventos. Os algoritmos utilizados para solução são: *Gray Wolf Optimiser* (Otimização do Lobo Cinzento), seno e cosseno, e *Crow Search* (busca do corvo). A proposta do trabalho é também otimizar a solução baseada no gerenciamento da demanda do lado da carga (Basak; Dey; Bhattacharyya, 2022).

Demais autores, como Damodaran e Kamur (2018), utilizaram o Algoritmo de Otimização de Enxame de Partículas Modificado (MPSO) para solucionar um problema de DEA em um sistema de energia incluindo térmicas, hidrelétricas e usinas eólicas. A solução foi comparada com outros métodos, como: Algoritmo Genético Codificado Binário (BCGA), Otimização de Enxame de Partículas (PSO), Busca de Harmonia Aprimorada (IHS) e algoritmo JAYA. O MPSO proporcionou uma melhor solução para o problema com custo de geração reduzido e menos emissão de poluição quando comparado com outros algoritmos.

Outro estudo de Ryu e Kim (2020) baseou-se na resposta à demanda do meio ambiente. O Estudo Básico de Desenvolvimento Regional (EBDR) é um algoritmo usado para implementar a redução de emissão de poluentes e facilitar a melhoria econômica. Através do Algoritmo de Atualização de Ponderação Artificial de Colônia de Abelhas (WU-ABC) é utilizado para resolver o problema do DEA em um sistema-teste com microgeração (MGs).

Em outra referência (Habibi *et al.*, 2020) encontrou-se o uso do Algoritmo de Otimização de Enxame de Partículas Multiobjetivo (MOPSO) em sistemas-teste do IEEE com inserção de geração eólica, cuja modelagem foi com base na distribuição de *Weibull*. Teve-se a expectativa de representar a característica imprevisível dos ventos.

A energia eólica vem se tornando cada vez mais eficiente e econômica, sendo considerada umas das técnicas mais maduras em geração de energia renovável, apresentando potencial para redução das emissões de poluentes em um despacho de geração. Entretanto, a natureza de flutuação e impressibilidade do vento torna a tarefa do DEA mais complexa, no sentido de atender ao equilíbrio da oferta e demanda de energia, levando em conta os aspectos econômicos e ambientais.

Constata-se, na revisão de literatura, a descrição sistemática de vários métodos para resolver o problema DEA. Entretanto, existem infinitas combinações, envolvendo enxame de partículas quânticas e métodos de controle de parâmetros que podem ser ajustados e melhorados, trazendo soluções otimizadas ao problema. Assim, há sempre uma implementação que pode ser utilizada para encontrar talvez a mesma solução para o problema, mas com desempenhos diferentes.

Observa-se, ainda, poucos estudos com a presença de energia eólica no DEA. Muito provavelmente se deve ao fato do comportamento imprevisível do vento, o que torna a modelagem mais complexa. Tal situação justifica a importância da proposta deste trabalho, uma vez que busca uma melhor representação dessa característica. Além disso, há escassez de pesquisas envolvendo a solução do DEA utilizando algoritmos quânticos. Esses algoritmos são ferramentas computacionais utilizadas para processar informação, construídas usando portas lógicas quânticas.

A promessa dos computadores quânticos é possibilitar novos algoritmos que tornem tratáveis problemas com solução que exigem recursos exorbitantes em um computador clássico. Devido à dificuldade da implementação de computadores quânticos, vários pesquisadores desenvolveram algoritmos com inspiração na mecânica quântica para serem utilizados em computadores clássicos. Ao invés de investir em novas técnicas para poder usufruir da computação quântica, a computação com inspiração quântica desenvolve algoritmos clássicos que utilizam os efeitos quânticos para melhorar o seu desempenho na resolução de problemas (Vianna Neto; Bernert; Coelho, 2009).

Muitos problemas interessantes são impossíveis de resolver em computadores clássicos, e em computadores quânticos, possuem solução viável, o que também justifica a utilização de algoritmos quânticos no presente trabalho.

1.7 Organização do trabalho

Além deste capítulo inicial, o restante desta dissertação está organizado em mais quatro capítulos que são descritos resumidamente a seguir.

O capítulo 2 trata da teoria e modelagem do DE e DEA, ambos considerando restrições operativas. O capítulo 3 versa sobre os algoritmos quânticos utilizados na otimização do problema DEA. Além disso, é apresentada a modelagem da energia eólica utilizada no trabalho, incluindo a integração dessa energia no problema DEA.

No capítulo 4 são apresentados os sistemas-teste utilizados na pesquisa, bem como detalhamento das simulações realizadas, evidenciando os resultados e a comparação de desempenho dos algoritmos. Já o capítulo 5 apresenta as principais conclusões do trabalho e proposta de desenvolvimentos futuros.

2 DESPACHO ECONÔMICO E AMBIENTAL

Este capítulo visa explorar o conceito do DEA de energia, que é essencial para equilibrar a eficiência financeira e o respeito ao meio ambiente na gestão de energia. Busca-se entender como a problemática do DE e do DEA otimiza a distribuição de recursos elétricos para atender à crescente demanda por eletricidade, ao mesmo tempo em que se minimiza os impactos ambientais ocasionados pela emissão de poluentes em decorrência da geração de energia.

2.1 Despacho Econômico de energia

Segundo Gomez-Exposito, Conejo e Canizares (2009), o problema do DE consiste em alocar a demanda total entre as unidades geradoras, de modo que o custo de produção seja minimizado. As unidades geradoras possuem custos de produção diferentes, dependendo da fonte primária de energia utilizada para gerar eletricidade (principalmente carvão, óleo, gás natural, urânio e água armazenada em reservatórios).

A formulação matemática do DE é representada primeiramente pela função quadrática do custo $C_i(P_i)$, que expressa o custo de geração de cada máquina, e é dada pela Equação 1.

$$C_i(P_i) = a_i P_i^2 + b_i P_i + c_i \quad (1)$$

Os coeficientes a_i , b_i e c_i representam as características das máquinas i , que dependem do tipo da fonte de geração, e P_i representa a potência gerada por elas. Esta função caracteriza o custo de geração individual das máquinas em \$/h em termos da potência gerada em MW, durante 1 hora.

O problema do DE consiste em minimizar o custo total de combustível utilizado pela geração. O custo total é representado pela função-objetivo expressa pela Equação 2, considerando n unidades geradoras.

$$C(P) = \sum_1^n C_i(P_i) \quad (2)$$

Além de apenas minimizar a função objetivo, o DE precisa atender às restrições que serão mencionadas no tópico seguinte.

2.2 Despacho Econômico e Ambiental

Desde que as questões ambientais – causadas pelas emissões de poluentes provenientes de usinas de energia movidas a combustíveis fósseis – tornaram-se uma preocupação, fez-se necessário evoluir o DE para o DEA, que leva em consideração tanto as questões econômicas quanto as ambientais.

Além do custo econômico ocasionado pelo consumo de combustível dos geradores, o DEA considera o custo ambiental associado à emissão de poluentes em decorrência da produção de energia pela queima de combustíveis fósseis.

A função quadrática que representa o impacto ambiental de emissão de uma máquina (Bayon *et al.*, 2012) é dada por:

$$E_i(P_i) = d_i P_i^2 + e_i P_i + f_i \quad (3)$$

Onde:

- E_i é a emissão de gases nocivos em (kg/h);
- P_i a potência gerada (MW);
- d_i , e_i e f_i representam as características de emissão de cada unidade.

O valor de emissão total em kg/h é expresso pela Equação 4, que corresponde ao somatório de emissão de cada unidade geradora, dada por:

$$E(P) = \sum_1^n E_i(P_i) \quad (4)$$

Dessa forma, o problema de DEA, com n unidades geradoras, consiste em minimizar duas funções objetivas conflitantes: o custo do combustível (Equação 2) e as emissões (Equação 4). Além disso, o problema DEA, além de minimizar os custos, consiste em atender às restrições de balanço de carga. A potência total gerada deve suprir a demanda total somada às perdas do sistema. Desta forma, a primeira restrição a ser atendida é:

$$\sum_1^n P_i = P_D + P_L \quad (5)$$

Onde:

- P_D é a demanda total do sistema em MW;
- P_L é a perda de transmissão em MW.

Quando as distâncias de transmissão são muito pequenas e a densidade de carga é muito alta, as perdas de transmissão podem ser negligenciadas, e o despacho ótimo de geração é alcançado com todas as usinas operando a custos incrementais de produção iguais. No entanto, em uma grande rede interconectada, onde a energia é transmitida por longas distâncias em áreas de baixa densidade de carga, as perdas de transmissão são um fator importante e afetam o despacho ótimo de geração. Uma prática comum para incluir o efeito das perdas de transmissão é expressar a perda total como uma função quadrática das saídas de potência dos geradores (Saadat, 1999). A forma mais simples para representá-las é:

$$P_L = \sum_1^n \sum_1^n P_i B_{ij} P_j \quad (6)$$

Os coeficientes B_{ij} são chamados de *coeficientes de perda* ou *B-coeficientes*. Os *B-coeficientes* são considerados constantes, e pode-se esperar uma precisão razoável desde que as condições de operação reais estejam próximas do caso base onde os *B-coeficientes* foram calculados (Saadat, 1999). Existem várias maneiras de chegar a uma Equação de perda, porém, fogem do escopo deste trabalho, não cabendo explorá-las.

Outra restrição que contribui para complexidade do problema DEA, restrição essa considerada neste trabalho, é a capacidade de geração de cada máquina, representada por uma restrição de desigualdade. Para uma operação estável, a potência ativa P_i de cada gerador é restringida pelos limites superior e inferior (Brito Júnior, 2018). A representação é dada pela Equação 7:

$$P_{Mini} \leq P_i \leq P_{Maxi} \quad (7)$$

Onde:

- P_i – Potência de saída do gerador i ;
- P_{Mini} – Potência mínima do gerador i ;
- P_{Maxi} – Potência máxima do gerador i .

Na formulação do DEA, o problema de otimização multiobjetivo pode ser convertido em uma otimização de objetivo único usando um fator de conversão de preço k_i . O fator de conversão de preço tenta integrar o custo de emissão (kg/h) com o custo de combustível (\$/h), dando igual importância a ambos. Assim, o custo operacional total do sistema de energia é o custo de combustível das unidades geradoras mais o custo equivalente de emissão (Jiang; Ji; Wang, 2015). Portanto, a função objetivo geral do problema DEA, agregando os dois objetivos e as restrições acima mencionadas, pode ser formulado com a ajuda do valor do fator de conversão k_i , e é representada como:

$$\begin{aligned} \text{Minimizar:} \quad & CT = \delta \cdot \sum_1^n C_i(P_i) + (1 - \delta) \cdot k_i \cdot \sum_1^n E_i(P_i) \\ \text{Sujeito a:} \quad & \sum_1^n P_i = P_D + P_L \\ & P_{Mini} \leq P_i \leq P_{Maxi} \end{aligned} \quad (8)$$

Onde:

– CT é o custo total de geração em \$/h.

O detalhe do cálculo para encontrar a variável δ é apresentado em Gherbi, Bouzeboudja e Gherbi (2016). A variável δ é o fator de ponderação, utilizado para geração da curva de Pareto e o seu valor varia uniformemente entre 0 e 1, geralmente ao passo de 0,05.

2.3 Curva de Pareto

O conjunto das soluções ótimas para um problema de otimização multiobjetivo é chamado de *fronteira de Pareto* ou *conjunto de Pareto*. Esse conceito foi introduzido nos anos 70, por Vilfredo Pareto, que estudava o bem-estar de uma sociedade (Pareto, 1971). A fronteira de Pareto representa uma configuração da sociedade, tal que a melhoria do bem-estar de um ou mais indivíduos implica necessariamente a diminuição do bem-estar de pelo menos outro indivíduo. De maneira mais geral, uma solução é dita Pareto-ótima se ela não é dominada por nenhuma outra solução possível, ou seja, não existe outra solução melhorando pelo menos um objetivo sem prejudicar a um ou a mais outros objetivos (Bigot, 2015).

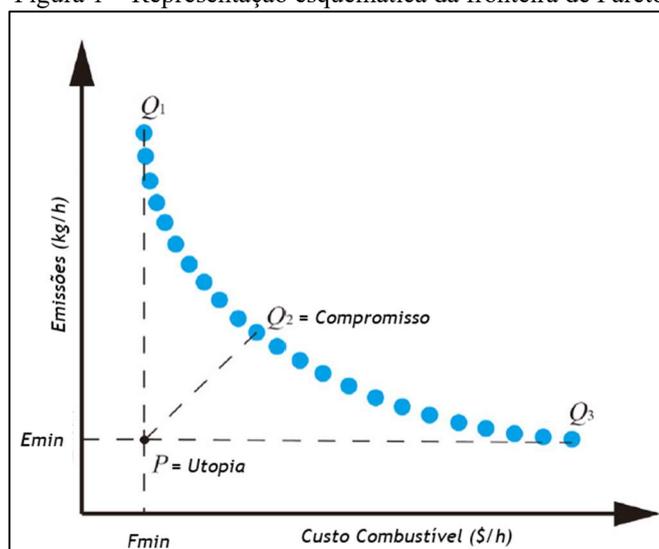
Aplicada ao contexto do DEA, a fronteira de Pareto representa o conjunto de soluções que fornecem um desempenho ótimo: não existe outro resultado que possa melhorar um objetivo de desempenho do sistema sem prejudicar pelo menos outro objetivo de desempenho,

pois os objetivos econômicos e ambientais são conflitantes. A vantagem dessa abordagem é que permite obter um conjunto de soluções ótimas, e depois escolher de maneira visual e gráfica, qual é o resultado que corresponde ao melhor desempenho desejado (Bigot, 2015).

Vários métodos para gerar conjuntos de Pareto continuam sendo objeto de pesquisa, incluindo amostragem aleatória, método de ponderação, método de distância, método de troca de compromisso restrito, método de interseção de fronteira normal, programação de metas, algoritmo genético de Pareto etc. (Bayon *et al.*, 2012). Para este trabalho, o método utilizado para geração do Pareto é o da soma ponderada, em que um conjunto de soluções pode ser obtido variando o peso na função objetivo. Na função objetivo (Equação 8) o peso é representado pela variável δ , que é o fator de ponderação, e o seu valor varia uniformemente entre 0 e 1, geralmente ao passo de 0,05.

Para encontrar a solução ótima para um problema multiobjetivo através da fronteira de Pareto, técnicas são implementadas na literatura. Em Zavala e Tlacuahuac (2012) foi proposta uma técnica para rastrear o ponto de utopia através da fronteira de Pareto. Conforme a Figura 1, o ponto de utopia P é inatingível, e corresponde à intersecção do custo mínimo de cada objetivo independente, E_{min} e F_{min} . O ponto da curva de Pareto, Q_2 , que tem a menor distância ao ponto de utopia, corresponde à solução ótima do problema, conhecido como *ponto de compromisso*. Quanto menor a distância do ponto de compromisso ao ponto de utopia, melhor é a solução do problema.

Figura 1 – Representação esquemática da fronteira de Pareto



Fonte: adaptado de Xiong, Shuai e Hu (2022).

2.4 Integração da energia eólica ao problema multiobjetivo

A inclusão da geração eólica no DEA envolve a avaliação e otimização da produção de energia eólica em conjunto com outras fontes de geração no sistema elétrico, considerando fatores econômicos e ambientais.

Ao integrar a geração eólica nesse contexto, é crucial considerar a variabilidade e intermitência naturais da energia eólica, dada a não constância da velocidade do vento. Isso implica ajustar dinamicamente a alocação de carga entre as unidades geradoras, que podem incluir aquelas impulsionadas por fontes convencionais, como carvão, óleo, gás natural, bem como energia hidrelétrica, nuclear e, evidentemente, eólica.

2.4.1 Modelo da energia eólica no DEA

Para utilizar uma turbina eólica no problema de DE, e devido à característica estocástica do vento, as funções de distribuição de probabilidade e de distribuição cumulativa de *Weibull* são usadas para modelar a velocidade do vento, como expressas a seguir (Hagh; Kalajahi; Ghorbani, 2020):

$$F_V(v) = 1 - \exp\left[-\left(\frac{v}{c}\right)^k\right], [v \geq 0] \quad (9)$$

$$f_V(v) = \frac{k}{c} \left(\frac{v}{c}\right)^{k-1} \exp\left[-\left(\frac{v}{c}\right)^k\right] \quad (10)$$

A Equação 9 é a Função de Distribuição Cumulativa (FDC) e a Equação 10 é a Função de Distribuição de Probabilidade (FDP), onde v é a velocidade do vento em (m/s), k é o fator de forma em um local específico (adimensional) e c é o fator de escala em um local específico (m/s).

Por outro lado, a potência gerada por uma turbina eólica varia em diferentes velocidades do vento, e pode ser expressa por (Hagh; Kalajahi; Ghorbani, 2020):

$$\begin{cases} w = 0 & \text{para } v < v_i \text{ e } v > v_o \\ w = w_r \frac{(v-v_i)}{(v_r-v_i)} & \text{para } v_i \leq v \leq v_r \\ w = w_r & \text{para } v_r < v \leq v_o \end{cases} \quad (11)$$

Onde:

- v é a velocidade atual do vento em (m/s);
- v_i , v_o e v_r são as velocidades do vento de acionamento, desligamento e nominal, respectivamente;
- w é a potência de saída da turbina (MW) e;
- w_r é a potência nominal da turbina.

O sistema de Equações de 11 representa que, quando a velocidade atual do vento for menor que a velocidade de acionamento ou maior que a velocidade de desligamento, a potência elétrica de saída da turbina é nula. No instante em que a velocidade atual do vento estiver entre as velocidades de acionamento e a nominal, é gerada potência de saída de forma linear. Quando a velocidade atual do vento estiver entre a nominal e a velocidade de desligamento, a potência de saída é igual à potência nominal da turbina.

Usando as equações 9 e 11, a probabilidade de acontecer um cenário em que $w = 0$ e $w = w_r$ são expressas pelas seguintes fórmulas (Hagh; Kalajahi; Ghorbani, 2020):

$$P_r\{w = 0\} = F_V(v_i) + (1 - F_V(v_o)) = 1 - \exp\left[-\left(\frac{v_i}{c}\right)^k\right] + \exp\left[-\left(\frac{v_o}{c}\right)^k\right] \quad (12)$$

$$P_r\{w = w_r\} = F_V(v_o) + (1 - F_V(v_r)) = \exp\left[-\left(\frac{v_r}{c}\right)^k\right] - \exp\left[-\left(\frac{v_o}{c}\right)^k\right] \quad (13)$$

Onde:

- v_i , v_o e v_r representam as velocidades do vento de acionamento, de desligamento e nominal, respectivamente;
- F_V é a função de distribuição cumulativa
- o parâmetro k é o fator de forma dado da especificidade de um local.

Para modificar as duas variáveis aleatórias de velocidade do vento e a potência de saída da turbina eólica em um intervalo contínuo, são utilizadas duas razões da seguinte forma (Hagh; Kalajahi; Ghorbani, 2020):

- $\rho = w/w_r$: essa razão representa a relação entre a potência de saída da energia eólica e a potência nominal do vento;
- $l = (v_r - v_i)/v_i$: essa razão representa uma faixa linear da velocidade do vento em relação à razão de velocidade do vento de entrada.

Segundo Hetzer, David e Bhattarai (2008), a PDF de Weibull da variável aleatória de saída de potência da turbina eólica em um intervalo contínuo é expressa pela Equação 14:

$$f_w(w) = \frac{kl}{w_r c} \left(\frac{(1+\rho l)v_i}{c}\right)^{k-1} \exp\left(-\left(\frac{(1+\rho l)v_i}{c}\right)^k\right) \quad 0 < w < w_r \quad (14)$$

2.4.2 Formulação do problema DEA com energia eólica

Para integração da energia eólica no problema DEA, é necessário primeiramente encontrar o custo de produção da energia proveniente dos ventos, pois é uma componente que vai ser incrementada na formulação geral do DEA (Equação 8). Vale ressaltar que o custo da geração eólica $Y_j(W_j)$ entra como um custo econômico dentro do problema multiobjetivo.

A solução geral do DEA com energia eólica é encontrada mediante a resolução da expressão matemática seguinte (Mondal; Bhattacharya; Dey, 2013):

$$\begin{aligned} \text{Minimizar:} \quad & CT = \delta \cdot \left(\sum_1^n C_i(P_i) + \sum_1^n Y_{wj}(W_j)\right) + (1 - \delta) \cdot k_i \cdot \sum_1^n E_i(P_i) \\ \text{Sujeito a:} \quad & \sum_1^n P_i + \sum_1^n W_j = P_D + P_L \\ & P_{Mini} \leq P_i \leq P_{Maxi} \\ & 0 \leq W_j \leq W_{r,j} \end{aligned} \quad (15)$$

Onde:

- $C_i(P_i)$: Custo de produção da unidade térmicas em \$/h (Equação 1);
- $Y_{wj}(W_j)$: Custo de produção de energias eólicas em \$/h;
- $E_i(P_i)$: Emissão de poluentes em kg/h (Equação 3);
- P_i : Potência gerada pela inésima máquina térmica em MW;
- P_D : Demanda do sistema em MW;
- P_L : Perdas do sistema em MW (Equação 6);

- W_j : Potência gerada pela j -ésima geração eólica em MW;
- P_{Mini} e P_{Maxi} : Limites de capacidade nominal de cada máquina térmica MW;
- $W_{r,j}$: Potência nominal de cada gerador eólico MW;
- δ : Fator de ponderação para geração da curva de Pareto;
- k_i : Fator de conversão de preço;

Nota-se que a formulação acima é equivalente à Equação 8, divergindo a inserção da parcela relacionada com o custo da produção de energia eólica $\sum_1^n Y_j(W_j)$. Nas restrições, o problema multiobjetivo deve atender ao de balanço de potência, em que foi inserida a geração eólica total em MW, representada por: $\sum_1^n W_j$. E, por fim, outra restrição que precisa ser atendida é a limitação de potência da energia eólica dada por: $0 \leq W_r \leq W_{r,j}$.

A Equação 16 descreve o custo total da geração eólica Y_w , que já foi tratada com derivações e integrações por Liu e Xu (2010):

$$Y_w = \sum_1^m (WC_{o,j} + WC_{u,j} + WC_{d,j}) = \sum_1^m (C_{o,j} \cdot E(Y_{o,j})) + \sum_1^m (C_{u,j} \cdot E(Y_{u,j})) + \sum_1^m (C_{d,j} \cdot w_j) \quad (16)$$

A formulação acima é composta por três parcelas, onde $WC_{o,j}$ é o custo médio escalar de superestimação, $WC_{u,j}$ custo médio escalar de subestimação e $WC_{d,j}$ custo direto de geração da energia eólica, ambos da j -ésima fonte de geração eólica.

O custo de superestimação é aplicado quando a energia eólica assumida (compromissada) é maior do que a energia eólica disponível no momento, desta forma é necessário comprar energia de outra fonte ou cortar carga do sistema. Já o custo de subestimação é o preço pago pelo excedente de energia produzida, momento em que a produção é maior que o consumo. O custo direto diz respeito ao que é produzido em energia eólica, e é instantaneamente consumido pela carga do sistema.

Na primeira parcela $WC_{o,j} = C_{o,j} \cdot E(Y_{o,j})$, onde $C_{o,j}$ e $E(Y_{o,j})$ são o coeficiente de custo de superestimação e potência eólica superestimada da j -ésima turbina eólica. $E(Y_{o,j})$ é representado pela seguinte formulação, conforme desenvolvido por Hetzer, David e Bhattacharai (2008):

$$E(Y_{o,j}) = (w_j\{1 - \exp(-(v_i/c)^k) + \exp(-(v_o/c)^k)\} + (w_r v_i/(v_r - v_i) + w_j)(\exp(-(v_i/c)^k) - \exp(-(v_j/c)^k)) + (w_r c/(v_r - v_i))(\Gamma[1 + \frac{1}{k}, (v_i/c)^k] - \Gamma[1 + \frac{1}{k}, (v_j/c)^k])) \quad (17)$$

Na segunda parcela $WC_{u,j} = C_{u,j} \cdot E(Y_{u,j})$, onde $C_{u,j}$ e $E(Y_{u,j})$ são o coeficiente de custo de subestimação e potência eólica subestimada da j -ésima turbina eólica, $E(Y_{u,j})$ é representado pela seguinte formulação (Hetzer; David; Bhattacharai, 2008):

$$E(Y_{u,j}) = (w_r - w_j)[\exp(-(v_r/c)^k) - \exp(-(v_o/c)^k)] + (w_r v_i/(v_r - v_i) + w_j)(\exp(-(v_r/c)^k) - \exp(-(v_j/c)^k)) + (w_r c/(v_r - v_i))(\Gamma[1 + \frac{1}{k}, (v_r/c)^k] - \Gamma[1 + \frac{1}{k}, (v_j/c)^k]) \quad (18)$$

Onde:

- w_r , w_j são as potencias nominal e gerada de cada turbina eólica;
- v_i , v_o e v_r representam as velocidades do vento de acionamento, de desligamento e nominal, e;
- c e k são o fator de escala e fator de forma, respectivamente, de um determinado local;
- $\Gamma(\cdot)$ é a função gama incompleta, suportada pelo *software* MatLab.

A terceira parcela da Equação $WC_{d,j} = C_{d,j} \cdot w_j$, que é o custo direto da geração de energia eólica quando os sistemas de conversão de energia eólica têm proprietários, com base em acordos contratuais especiais, $C_{d,j}$ é o coeficiente de custo de geração e w_j é a potência gerada da energia eólica.

3 META-HEURÍSTICAS QUÂNTICAS

O presente capítulo explora os métodos matemáticos aplicados à otimização, desde abordagens clássicas até o emergente campo dos algoritmos quânticos. Ao longo dos anos, testemunha-se a ascensão de técnicas tradicionais, como programação linear e não linear, para solucionar problemas de otimização em diversas disciplinas. As técnicas de otimização chamadas de meta-heurísticas, como PSO, *Grey Wolf Optimizer* (GWO) e Otimização por Polinização das Flores (FPA), ganharam considerável popularidade.

Essas abordagens, inspiradas em conceitos simples relacionados com fenômenos físicos, comportamentos animais e evolução, são amplamente reconhecidas em diversas áreas de conhecimento. A proliferação dessas meta-heurísticas pode ser atribuída a quatro principais razões: simplicidade, flexibilidade, mecanismos isentos de derivadas e capacidade de evitar ótimos locais (Mirjalili; Mirjalili; Lewis, 2014).

Contudo, diante da crescente demanda por soluções mais eficazes e rápidas, a atenção voltou-se para a computação quântica e seus algoritmos inovadores. Os algoritmos quânticos são variantes que consideram o comportamento quântico de fenômenos naturais, como: partículas, polinização de flores e movimento de animais, com base nas leis da mecânica quântica, e que, em teoria, apresentam melhor convergência global em relação aos algoritmos convencionais, a depender da natureza do problema de otimização.

A seguir, são apresentados os algoritmos clássicos e suas variantes quânticas, utilizadas para solução do problema DEA neste trabalho.

3.1 Otimização por Enxame de Partículas (PSO e QPSO)

3.1.1 Otimização de Enxame de Partículas

A PSO é um algoritmo estocástico de otimização baseado em população, que se inspira na metáfora da interação social e comunicação observada em fenômenos como o voo de pássaros e a formação de cardumes de peixes. A implementação dos algoritmos PSO é simples, e sua execução é computacionalmente eficiente, requerendo ajustes apenas em um pequeno conjunto de parâmetros.

No PSO, as partículas, que representam soluções potenciais movem-se em um espaço de busca multidimensional. Sua velocidade é continuamente atualizada com base na experiência da própria partícula e na experiência dos vizinhos da partícula, ou até mesmo na

experiência de todo o enxame. Essa abordagem compartilha semelhanças com algoritmos evolutivos, e tem demonstrado um desempenho robusto em uma ampla variedade de desafiantes problemas de otimização (Sun *et al.*, 2011).

Para Sun *et al.* (2011), no PSO original com M partículas, cada partícula é representada como uma solução potencial para um problema em um espaço dimensional D, e sua posição na t-ésima iteração é indicada como $X_i^t = [X_{i,1}^t, \dots, X_{i,j}^t, \dots, X_{i,D}^t]$. Cada partícula lembra sua própria melhor posição anterior, e sua velocidade ao longo de cada dimensão como $V_i^t = [V_{i,1}^t, \dots, V_{i,j}^t, \dots, V_{i,D}^t]$. A velocidade e a posição da partícula i na $(t + 1)$ -ésima iteração são atualizadas pelas seguintes equações:

$$V_{ij}^{t+1} = wV_{ij}^t + c_1r_{ij}^t(P_{ij}^t - x_{ij}^t) + c_2R_{ij}^t(G_j^t - X_{ij}^t) \quad (19)$$

$$X_{ij}^{t+1} = X_{ij}^t + V_{ij}^{t+1} \quad (20)$$

Onde:

- c_1 e c_2 são duas constantes positivas, conhecidas como *coeficientes de aceleração*;
- $r_{i,j}^t$ e $R_{i,j}^t$ são dois números aleatórios uniformemente distribuídos no intervalo (0,1) para a j -ésima dimensão da partícula i .

O vetor $P_i^t = [P_{i,1}^t, \dots, P_{i,j}^t, \dots, P_{i,D}^t]$ é a posição com o melhor ajuste encontrado até agora para a i -ésima partícula, chamada de *posição pessoal melhor (pbest)*. E o vetor $G^t = [G_1^t, \dots, G_j^t, \dots, G_D^t]$ registra a melhor posição descoberta pelo enxame até agora, conhecida como a *posição global melhor (gbest)*. $X_{i,j}^t$, $V_{i,j}^t$ e $P_{i,j}^t$ são a j -ésima dimensão dos vetores X_i^t , V_i^t e P_i^t , respectivamente. O parâmetro w é o peso de inércia usado para equilibrar as habilidades de busca global e local. Normalmente, w diminui linearmente com as gerações de iteração, conforme:

$$w = w_{\max} - t \cdot (w_{\max} - w_{\min})/T \quad (21)$$

Onde:

- w_{max} e w_{min} são os pesos máximo e mínimo, geralmente ajustados para 0,9 e 0,4, respectivamente;
- T é um número máximo de iterações predefinido, e;
- t representa o número da iteração atual.

Seja f a função objetivo a ser minimizada. O algoritmo PSO pode ser descrito pelo pseudocódigo do Quadro 1.

Quadro 1 – Pseudocódigo do PSO

<p><i>Gerar aleatoriamente uma população inicial com posições e velocidades</i></p> <p>Repetir</p> <p style="padding-left: 2em;">Para i de 1 até o tamanho da população M faça:</p> <p style="padding-left: 4em;"><i>Se</i> $f(X_i) < f(P_i)$ <i>então</i> $P_i = X_i$;</p> <p style="padding-left: 4em;">$G = \arg \min(f(P_j))$;</p> <p style="padding-left: 2em;">Para j de 1 até D faça:</p> <p style="padding-left: 4em;"><i>Atualizar velocidade com a Equação (17);</i></p> <p style="padding-left: 4em;"><i>Atualizar posição com a Equação (18);</i></p> <p style="padding-left: 2em;">Fim//fim do loop para j</p> <p style="padding-left: 2em;">Fim//fim do loop para i</p> <p>Até que o critério de término seja atendido.</p>

Fonte: elaborado pelo autor.

3.1.2 Quantum Particle Swarm Optimizer

O QPSO é embasado nos princípios da mecânica quântica e na análise de trajetória do PSO. Este algoritmo adota uma estratégia fundamentada em um modelo de poço de potencial delta quântico para realizar amostragens ao redor dos pontos ótimos previamente identificados. Além disso, busca aprimorar a posição média da partícula com o intuito de reforçar a capacidade de busca global. O QPSO representa uma abordagem algorítmica probabilística, diferenciando-se em vários aspectos do PSO convencional (Sun *et al.*, 2011 *apud* Filho, 2018).

Após o desenvolvimento matemático do QPSO apresentado em Sun *et al.* (2011), pode-se definir o vetor C como a posição média ótima (*mbest*), definida como a média das posições *pbest* de todas as partículas, representada por:

$$C^t = (C_1^t, C_2^t, \dots, C_D^t) = \left(\frac{1}{M} \sum_{i=1}^M P_{i,1}^t, \frac{1}{M} \sum_{i=1}^M P_{i,2}^t, \dots, \frac{1}{M} \sum_{i=1}^M P_{i,j}^t, \dots, \frac{1}{M} \sum_{i=1}^M P_{i,D}^t \right) \quad (22)$$

Onde:

- M é o tamanho da população, e;

– P_i^t ($pbest$) é a melhor posição pessoal da partícula i .

Portando, a posição da partícula é atualizada de acordo com a Equação 23:

$$X_{ij}^{t+1} = \begin{cases} p_{i,j}^t + \alpha |C_j^t - X_{i,j}^t| \ln\left(\frac{1}{u_{i,j}^{t+1}}\right), & \text{se } r_1 > 0,5 \\ p_{i,j}^t - \alpha |C_j^t - X_{i,j}^t| \ln\left(\frac{1}{u_{i,j}^{t+1}}\right), & \text{se } r_1 \leq 0,5 \end{cases} \quad (23)$$

Onde:

– $u_{i,j}^{t+1}$ é um número uniformemente aleatório;

– r_1 é uma constante, também uniformemente aleatória.

O parâmetro α é o coeficiente de contração da expansão, responsável pelo controle da velocidade de convergência. De acordo com Sun *et al.* (2011 *apud* Filho, 2018), o valor de α diminui de maneira linear de α_1 até α_0 , conforme a Equação 24.

$$\alpha = \alpha_0 + (T - t) \cdot (\alpha_1 - \alpha_0) / T \quad (24)$$

Onde:

– α_1 e α_0 são os valores final e inicial de α , respectivamente;

– T é o número máximo de iterações, e;

– t é o número de iteração atual.

O vetor p_{ij} é denominado de *atrator local*, cujas coordenadas são definidas pela Equação 25.

$$p_{ij} = \varphi P_{ij} + (1 - \varphi)G_j \quad (25)$$

Onde φ é um número uniformemente aleatório.

De acordo com Sun, Xu e Feng (2004 *apud* Filho, 2018), o QPSO tem algumas vantagens em relação ao PSO, a saber:

- sistemas quânticos são sistemas complexos não lineares que se fundamentam no princípio da sobreposição de estados. Em outras palavras, os modelos quânticos possuem uma quantidade muito maior de estados em comparação com o modelo convencional;
- sistemas quânticos são sistemas incertos, o que os torna muito diferentes dos sistemas clássicos estocásticos. Antes da medição, as partículas podem estar em qualquer estado com uma certa probabilidade, já que não existe uma trajetória definida.

O procedimento para implementar o QPSO é dado pelos seguintes pseudocódigos apresentados no Quadro 2:

Quadro 2 – Pseudocódigo do QPSO

```

Inicialize o tamanho da população ( $M$ ), as posições e as dimensões das partículas;
Para  $t = 1$  até a máxima iteração  $T$ ;
  Calcular a posição média ótima  $C$  através da Equação 22;
   $\alpha = \alpha_0 + (T - t) \cdot (\alpha_1 - \alpha_0) / T$ ;
  Para  $i = 1$  até  $M$  (tamanho da população);
    Se  $f(X_i) < f(P_i)$  então  $P_i = X_i$ ; Fim se
     $G = \text{argmin}(f(P_j))$ ;
    Para  $j=1$  até  $D$ ;
       $\varphi = \text{rand}(0,1)$ ;  $u = \text{rand}(0,1)$ ;
      Calcular  $p_{ij}$ ;
      Atualizar posição da partícula  $X_{ij}$ 
    Fim para  $j$ 
  Fim para  $i$ 
Fim para  $t$ 

```

Fonte: elaborado pelo autor.

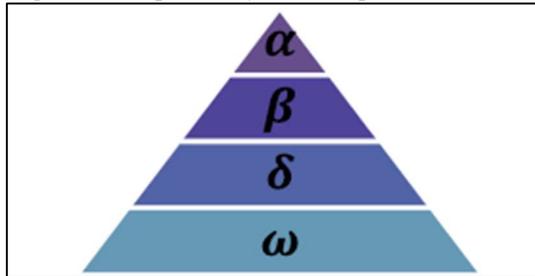
3.2 Otimização do Lobo Cinzento (GWO e QGWO)

3.2.1 Grey Wolf Optimizer

O algoritmo GWO é uma otimização baseada no comportamento de caça dos lobos cinzentos (*Canis Lupus*), e foi desenvolvido por Seyedali, Seyed e Andrew, em 2013, e vem sendo uma abordagem promissora no âmbito da inteligência de enxames (Mirjalili; Mirjalili; Lewis, 2014 *apud* Filho, 2018).

O lobo cinzento, líder na cadeia alimentar, vive em matilhas de cinco a 12 membros, e tem a sua hierarquia social dominante e rígida, conforme Figura 2. A liderança é feita por alfas, que podem ser machos e fêmeas, que decidem em conjunto. Há também comportamento democrático. Betas auxiliam os alfas e podem assumir o seu papel. Ômeegas são os mais baixos na hierarquia, mas cruciais para a estabilidade do grupo. Os subordinados desempenham funções vitais, como vigiar e cuidar do território.

Figura 2 – Representação hierárquica dos lobos cinzentos



Fonte: Mirjalili, Mirjalili e Lewis (2014).

Além do comportamento hierárquico dos lobos cinzentos, também é considerada na modelagem matemática do algoritmo o comportamento de caça em grupo, que tem as seguintes fases: rastreamento, perseguição e aproximação da presa; perseguindo, cercando e assediando a presa, até que ela pare de se mover; e por último ataque à presa.

Imagem 1 – Lobos cinzentos atacando presa



Fonte: Suzie (2010).

Na modelagem matemática da hierarquia social dos lobos, é atribuída a solução com melhor desempenho para os lobos alfa (α), e, conseqüentemente, as segunda e terceira soluções com melhor desempenhos são atribuídas aos grupos beta (β) e delta (δ). As demais soluções candidatas são assumidas como ômega (ω). Ou seja, a caçada é guiada pelos lobos α , β e δ , e os lobos ω seguem estes três primeiros.

Na caça, os lobos cercam a presa. O modelo matemático que descreve esse comportamento é dado pela Equação 26:

$$\begin{cases} \vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \\ \vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \end{cases} \quad (26)$$

Onde:

- t indica a iteração corrente;
- \vec{A} e \vec{C} são vetores coeficientes;
- $\vec{X}_p(t)$ indica a posição da presa, e;
- $\vec{X}(t)$ é a posição do lobo-cinzento.

Os vetores \vec{A} e \vec{C} são calculados pelas seguintes equações:

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (27)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (28)$$

Onde o parâmetro \vec{a} decai linearmente de 2 a 0 no decorrer das iterações e \vec{r}_1 e \vec{r}_2 são números aleatórios uniformes.

A caça à presa é protagonizada pelos lobos alfas, onde os betas e deltas ocasionalmente participam. A localização da presa é estimada pela posição dos lobos alfas, betas e deltas. Essa movimentação pode ser descrita pelas equações abaixo:

$$\begin{cases} \vec{D}_\alpha = |C_1 \cdot \vec{X}_\alpha(t) - \vec{X}(t)| \\ \vec{D}_\beta = |C_2 \cdot \vec{X}_\beta(t) - \vec{X}(t)| \\ \vec{D}_\delta = |C_3 \cdot \vec{X}_\delta(t) - \vec{X}(t)| \end{cases} \quad (29)$$

$$\begin{cases} \vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \\ \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \\ \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \end{cases} \quad (30)$$

$$\vec{X}(t + 1) = \frac{\vec{X}_1 - \vec{X}_2 + \vec{X}_3}{3} \quad (31)$$

O mecanismo de busca do GWO cria uma área de busca radial devido ao uso de três referências: alfa, beta e delta. O raio e as fases de busca variam de acordo com o parâmetro a , enquanto $a > 1$, ou seja, o número de iterações realizadas pelos algoritmos é inferior à metade das iterações que realizará o enxame tende a focar em uma busca global. De forma análoga, enquanto $0 < a < 1$, a tendência é de busca local.

O procedimento para implementar o GWO é dado pelos seguintes pseudocódigos, apresentado no Quadro 3:

Quadro 3 – Pseudocódigo do GWO

<p><i>Escolha da função objetivo e definição dos parâmetros do GWO</i> <i>Iniciar a população aleatoriamente;</i> <i>Avalia a função objetivo para todos os indivíduos: X_α é o melhor fitness X_β é o segundo melhor e X_δ é o terceiro melhor;</i> Enquanto ($t < iter_{max}$) Para cada indivíduo <i>Atualizar a posição da presa. (Equação 31)</i> Fim Para cada indivíduo <i>Atualizar a, A e C;</i> <i>Calcular fitness de todos os indivíduos;</i> <i>Atualizar X_α, X_β e X_δ</i> Fim Enquanto <i>Solução: X_α</i></p>
--

Fonte: elaborado pelo autor.

3.2.2 Quantum Gray Wolf Optimization

OQGWO é uma versão aprimorada do GWO. O sistema quântico introduz não linearidade e incerteza que podem localizar um lobo longe da população, o que leva a uma solução com melhor adaptação do que o algoritmo clássico GWO.

De acordo com Costa Filho (2023) e Vijay e Nanda (2019), a Equação 32 de atualização da posição dos lobos é:

$$X_{t+1}^i = C_\alpha g_t^i + \alpha |X_t^i - C_t| \ln\left(\frac{1}{u_t}\right) \quad (32)$$

Onde g_t^i é o atrator local dado por:

$$g_t^i = X_t^{av} + (1 - C_\alpha)X_t^\alpha + (1 - C_\beta)X_t^\beta + (1 - C_\delta)X_t^\delta \quad (33)$$

Onde $C_\alpha = 2.rand$, $C_\beta = 2.rand$, $C_\delta = 2.rand$ e $X_t^{av} = (X_t^\alpha + X_t^\beta + X_t^\delta)/3$ é a posição média dos três principais lobos.

O pseudocódigo do QGWO pode ser representado no Quadro 4, abaixo:

Quadro 4 – Pseudocódigo do QGWO

<p><i>Escolha da função objetivo e definição dos parâmetros do GWO</i> <i>Iniciar a população aleatoriamente;</i> <i>Avalia a função objetivo para todos os indivíduos: X_α é o melhor fitness X_β é o segundo melhor e X_δ é o terceiro melhor;</i> <i>Enquanto</i> ($t < iter_{max}$) <i>Para</i> cada indivíduo <i>Para</i> cada dimensão da posição do lobo Gerar um número aleatório entre 0 e 1; <i>Se</i> o número aleatório for menor que o pré definido Atualizar a posição do lobo quanticamente <i>Senão:</i> Atualizar posição do lobo pela regra padrão; <i>Fim Para</i> cada indivíduo Avaliar a função fitness <i>Se</i> a nova posição tiver um fitness melhor que a anterior Atualizar a posição do lobo; <i>Se</i> O fitness da nova posição for globalmente melhor; Atualizar a melhor posição Global; Atualizar a posição do lobo com base nas posições dos lobos alfa, beta e delta <i>Fim para</i> Incrementar número de iteração <i>Fim enquanto</i> Retornar melhor solução encontrada</p>

Fonte: elaborado pelo autor.

3.3 Otimização da Polinização das flores (FPA e QFPA)

3.3.1 Algoritmo de Otimização de Polinização das Flores

O FPA foi desenvolvido por Yang (2012). O autor propôs uma técnica de otimização inspirada no processo de polinização das plantas com flores, explorando os padrões de iteração entre flores e polinizadores para resolver problemas de otimização.

Existem duas formas de polinização: biótica, realizada por polinizadores, e abiótica, que não necessita deles. A maioria das plantas com flores depende da polinização biótica, enquanto o restante ocorre de forma abiótica, auxiliada pelo vento e pela difusão. A polinização pode ser realizada por autopolinização ou polinização cruzada, visando à sobrevivência e à reprodução ótima das plantas. Este processo pode ser considerado uma otimização das espécies vegetais, com todos os fatores envolvidos contribuindo para a reprodução ideal das plantas com

flores (Abdelaziz; Ali; Abd Elazim, 2016). Essa dinâmica pode servir de inspiração para o desenvolvimento de algoritmos de otimização.

Pode-se idealizar as seguintes características acima do processo de polinização, constância floral e comportamento dos polinizadores, como as seguintes regras:

- A polinização biótica e cruzada é considerada como um processo de polinização global com polinizadores carregadores de pólen realizando voos de Lévy;
- A polinização abiótica e autopolinização são consideradas como polinização local;
- A constância floral pode ser considerada como a probabilidade de reprodução é proporcional à similaridade de duas flores envolvidas;
- A polinização local e global é controlada por uma probabilidade de comutação;
- p pertencente ao intervalo $[0, 1]$. Devido à proximidade física e outros fatores como o vento, a polinização local pode ter uma fração significativa p nas atividades globais de polinização.

Baseado nas regras acima, a etapa de polinização global e a etapa de constância floral podem ser representadas por:

$$x_i^{t+1} = x_i^t + \gamma L(\lambda)(g_* - x_i^t) \quad (34)$$

Onde:

- x_i^t é o pólen;
- i, g_* é a melhor solução encontrada atualmente entre todas as soluções geradas;
- γ é um fator de escala para controle de passos.

$L(\lambda)$ é o tamanho do passo (distribuição de Levy) que corresponde à intensidade da polinização, que é baseado na distância percorrida do inseto para realizá-la.

$$L \sim \frac{\lambda \Gamma(\lambda) \sin(\frac{\pi\lambda}{2})}{\pi \cdot s^{1+\lambda}}, (s \gg s_0 \gg 0) \quad (35)$$

Onde $\Gamma(\lambda)$ é a função gamma padrão, e é válida para passos grandes $s > 0$. Para a polinização local e constância floral, ambas podem ser representadas por:

$$x_i^{t+1} = x_i^t + \varepsilon(x_j^t - x_k^t) \quad (36)$$

Onde x_j^t e x_k^t são pólenes de flores diferentes da mesma espécie de planta, imitando a constância floral em uma vizinhança limitada. Para uma busca local, se x_j^t e x_k^t vêm da mesma espécie, então ε é extraído de uma distribuição uniforme no intervalo $[0, 1]$.

O pseudocódigo do algoritmo FPA é apresentado abaixo, no Quadro 5:

Quadro 5 – Pseudocódigo do FPA

Entrar com a função objetivo ou multiobjetivo
Inicializar a população de número de flores/pólenes com soluções aleatórias
Encontrar a melhor solução g_ na população inicial*
Definir o valor da probabilidade p
Enquanto ($t < Max_{generation}$)
 Para $i = 1 : n$ (todas as n flores da população)
 Se $rand < p$,
 Defina a , passo do L distribuição de Levy
 Faça polinização global via Equação 34
 Senão
 Defina $\varepsilon [0,1]$;
 Escolher aleatoriamente j e k entre todas as soluções
 Faça polinização Local através da Equação 36
 Calcular novas soluções
 Se as soluções são melhores, atualizem elas na população
 Fim Para
 Encontre a melhor solução atual
Fim enquanto

Fonte: elaborado pelo autor.

3.3.2 Quantum Flower Polination Algorithm

No QFPA, assume-se que a partícula tem comportamento quântico, e sua posição e velocidade não podem ser determinadas simultaneamente de acordo com o princípio da incerteza. Portanto, a partícula comportamental quântica pode voar de forma mais aleatória no espaço de busca. Esse mecanismo de busca foi aplicado no FPA pela primeira vez por Lu e Li (2015), tornando o algoritmo de polinização das flores com uma maior capacidade de busca pela solução global.

O principal processo de busca no algoritmo FPA é o processo de polinização global, conforme Equação 34. Entretanto, o vetor de solução atualizado pela Equação 37 possui propriedades quânticas, o que é favorável para aprimorar a capacidade de convergência global. Desta forma, o algoritmo de polinização de flores – atualizado com o vetor de solução 37 em vez da Equação 34 – é chamado de algoritmo de Polinização de Flores com Comportamento Quântico/*Quantum Flower Polination Algorithm* (QFPA).

$$x_i^{t+1} = x_i^t + \gamma L(\lambda)(g_* - x_i^t) \pm \alpha |c^t - x_i^t| \ln\left(\frac{1}{u_i^t}\right) \quad (37)$$

O pseudocódigo do algoritmo QFPA pode ser apresentado no Quadro 6:

Quadro 6 – Pseudocódigo do QFPA

Definir função objetivo $f(x)$, onde $x = (x_1, x_2, \dots, x_d)$
 Inicializar uma população de M flores/gametas de pólen
 Encontrar a melhor solução g^* na população inicial
 Definir uma probabilidade de mudança p $[0, 1]$ e um fator de escala γ
Enquanto ($t < T$)
 Calcular
 Para $i=1$ até M
 Se ($\text{rand}(0,1) < p$)
 $u = \text{rand}(0,1)$
 $\alpha = 1 - t/T * 0.5$
 Desenhar um vetor de passo L que obedeça a uma distribuição de Lévy
 Se $\text{rand}(0,1) > 0.5$
 $x_i^{t+1} = x_i^t + \gamma L(\lambda)(g_* - x_i^t) + \alpha |c^t - x_i^t| \ln\left(\frac{1}{u_i^t}\right)$
 Senão
 $x_i^{t+1} = x_i^t + \gamma L(\lambda)(g_* - x_i^t) - \alpha |c^t - x_i^t| \ln\left(\frac{1}{u_i^t}\right)$
 Fim se
 Senão
 $\beta = \text{rand}(0,1)$
 $x_i^{t+1} = x_i^t + \varepsilon(x_j^t - x_k^t)$
 Fim se
 Avaliar as novas soluções
 Se as novas soluções forem melhores, atualizá-las
 Fim para
 Encontrar a melhor solução atual g^*
Fim enquanto

Fonte: elaborado pelo autor.

4 SIMULAÇÕES, RESULTADOS E DISCUSSÃO

Este capítulo apresenta a aplicação das meta-heurísticas quânticas apresentadas no capítulo anterior, onde foram realizadas comparações de desempenho entre elas. Para todas as simulações computacionais foi utilizado o *software* MatLab R2022b – 64/bit (MATLAB,2022) em um *notebook* com a seguinte configuração: processador AMD Ryzen 7, 3700U, 2.30 GHz e memória RAM de 8GB.

As simulações foram realizadas em dois sistemas-teste, um com seis geradores e em outro com 14 geradores, ambos sistemas do IEEE, e que foram submetidos a diferentes cenários de carga com e sem integração de sistemas de geração eólica. Também, nas simulações, as perdas de transmissão foram consideradas no balanço de potência. Nas funções objetivos, a limitação de potência de cada unidade geradora foi atribuída.

Cada algoritmo foi executado 200 vezes, para cada cenário, com o intuito de gerar parâmetros estatísticos como média, desvio e geração de *Box plots*. O valor de 200 foi utilizado de acordo com Hagh *et al.* (2020), que também usou o mesmo valor de execuções. Cada execução foi limitada a 600 iterações. Optou-se por utilizar 600 iterações pois representa um valor intermediário aos valores considerados em Parouha (2022), que utilizou 200 iterações e Xin-Gang *et. al.* (2020), 1000 iterações.

A seguir, são apresentados os detalhamentos e configurações de cada sistema-teste e seus respectivos Cenários de carga, bem como os resultados de cada simulação.

4.1 Sistemas-teste e representação da energia eólica

4.1.1 Sistema de 6 unidades geradoras

Nesta seção, são apresentados os parâmetros utilizados no sistema de seis unidades geradores, conforme Bayon *et al.* (2012), e a solução do DEA para este sistema, utilizando os algoritmos quânticos QGWO, QPSO e QFPA. Os algoritmos foram simulados com 600 iterações e rodados 200 vezes, a fim de gerar uma distribuição que obtivesse valores máximos, mínimos, médios e desvios, para posterior análise estatística dos custos econômicos e ambientais. Os coeficientes de cada máquina de custo econômico a , b e c , utilizados para compor a Equação 1, como os coeficientes de impacto ambiental d , e e f , para compor Equação 3, são apresentados na Tabela 1.

Tabela 1 – Coeficientes de custo e ambiental do sistema de seis geradores

Unidade	a_i	b_i	c_i	d_i	e_i	f_i
1	759,79886	38,53973	0,15247	13,85932	0,32767	0,00419
2	451,32513	46,15916	0,10587	13,85932	0,32767	0,00419
3	1049,32513	40,39655	0,02803	40,2669	-0,54551	0,00683
4	1243,5311	38,30553	0,3546	40,2669	-0,54551	0,00683
5	1658,5696	36,32782	0,02111	42,89553	-0,51116	0,00461
6	1356,65920	38,27041	0,01799	42,89553	-0,51116	0,00461

Fonte: Bayon *et al.* (2012).

A capacidade de geração das unidades geradores está limitada aos seguintes valores, de acordo com Bayon *et al.* (2012):

Tabela 2 – Limites operativos das unidades geradoras do sistema de seis geradores

Unidades	P_{min}	P_{max}
1	10	125
2	10	150
3	40	250
4	35	210
5	130	325
6	125	315

Fonte: Bayon *et al.* (2012).

Para representar as perdas do sistema, foi utilizado a matriz de perdas 3×3 com seus coeficientes, conforme Tabela 3, extraída de Bayon *et al.* (2012). As perdas foram calculadas utilizando a Equação 6. As seis unidades geradores foram agrupadas em três plantas de geração, sendo a primeira planta com as unidades 1, 2 e 3; e as unidades 4 e 5 atribuídas à planta 2; e, conseqüentemente, a unidade 6 foi atribuída à planta 3.

Tabela 3 – Matriz de Perdas B_{ij} .

B_{ij}	1	2	3
Planta 1	0,000091	0,000031	0,000029
Planta 2	0,000031	0,000062	0,000028
Planta 3	0,000029	0,000028	0,000072

Fonte: Bayon *et al.* (2012).

Para esse caso, o problema de otimização é dado conforme a Equação 8. O objetivo é minimizar a função custo, que está sujeita às restrições de desigualdade e igualdade, que são, respectivamente, as referidas capacidades limites de geração de cada unidade termoeletrica e o balanço de potência, considerando as perdas nas linhas de transmissão.

Em relação ao sistema de geração eólica, o modelo utilizado foi a formulação matemática apresentada por Hagh *et al.* (2020) pelas Equações 9 a 13. A função que originou o custo da geração eólica é expressa em Liu e Xu (2010), pela Equação 16. Na simulação de

seis geradores, considerou-se uma usina eólica de apenas uma unidade geradora, cujos parâmetros são apresentados na Tabela 4, obtidos da referência Guo *et al.* (2016).

Tabela 4 – Parâmetros da usina eólica

Vento	v_i	v_o	v_r	(c, k)
	5	45	15	8, 2
Turbina	C_{oj}	C_{uj}	C_{dj}	W_r
	3,1	3,1	6	160

Fonte: Guo *et al.* (2016).

A capacidade de geração máxima e mínima adotada para usina eólica utilizada na simulação do sistema de seis geradores foi de 100 e 10 MW.

4.1.2 Sistema de 14 unidades geradoras

Os dados do sistema de 14 geradores foram retirados da referência Gherbi, Bouzeboudja e Gherbi (2016). Os coeficientes de custo a , b e c e ambiental d , e e f do sistema são apresentados na Tabela 5. O problema multiobjetivo para o sistema, de acordo com Equação 8, foi solucionado através das meta-heurísticas quânticas QFPA, QPSO e QGWO. O processo de simulação foi semelhante ao sistema de seis geradores da seção anterior, onde cada algoritmo foi simulado 200 vezes com 600 iterações cada.

Tabela 5 – Coeficientes de custo e ambiental do sistema de 14 geradores

Unidade	a_i	b_i	c_i	d_i	e_i	f_i
1	0,0050	1,89	150,00	0,016	1,5	23,333
2	0,0055	2,00	155,00	0,031	1,820	21,022
3	0,0060	3,50	40,00	0,013	1,249	22,050
4	0,0050	3,15	122,00	0,012	1,355	22,983
5	0,0050	3,05	125,00	0,020	1,900	21,313
6	0,0070	2,75	120,00	0,007	0,805	21,900
7	0,0070	3,45	70,00	0,015	1,400	23,001
8	0,0070	3,45	70,00	0,018	1,800	24,003
9	0,0050	2,45	130,00	0,019	2,00	25,121
10	0,0050	2,45	130,00	0,012	1,360	22,990
11	0,0055	2,35	135,00	0,033	2,100	27,010
12	0,0045	1,60	200,00	0,018	1,800	25,101
13	0,0070	3,45	70,00	0,018	1,810	24,313
14	0,0060	3,89	45,00	0,030	1,921	27,119

Fonte: Gherbi, Bouzeboudja e Gherbi (2016).

Para este sistema, as perdas foram desprezadas. A capacidade de geração das unidades geradores está limitada aos seguintes valores, conforme Tabela 6:

Tabela 6 – Limites operativos das unidades geradoras do sistema de 14 geradores

Unidade	P_{min}	P_{max}
1	150	455
2	150	455
3	20	130
4	20	130
5	150	470
6	135	460
7	135	465
8	60	300
9	25	160
10	25	160
11	20	80
12	20	80
13	25	85
14	15	55

Fonte: Gherbi, Bouzeboudja e Gherbi (2016).

No sistema de 14 geradores considerou-se uma usina eólica com três unidades geradoras, cujos parâmetros são apresentados na Tabela 4, semelhante ao modelo usado para o sistema de seis geradores, obtidos da referência Guo *et al.* (2016). A turbina eólica de cada unidade foi limitada às capacidades máxima e mínima de 100 e 10 MW, respectivamente.

4.2 Simulações e resultados

4.2.1 Solução do DEA sem energia eólica – Sistema 6 geradores

– Cenário 1: demanda 900 MW e Cenário 2: demanda 1.170 MW

A primeira simulação consiste na otimização do DEA em dois Cenários distintos de carga para o sistema de seis geradores. Os Cenários 1 e 2 são representados pelo sistema de seis geradores com perdas, sem energia eólica, e com cargas de 900 e 1.170 MW, respectivamente. A Tabela 7 apresenta o resultado da simulação dos Cenários 1 e 2.

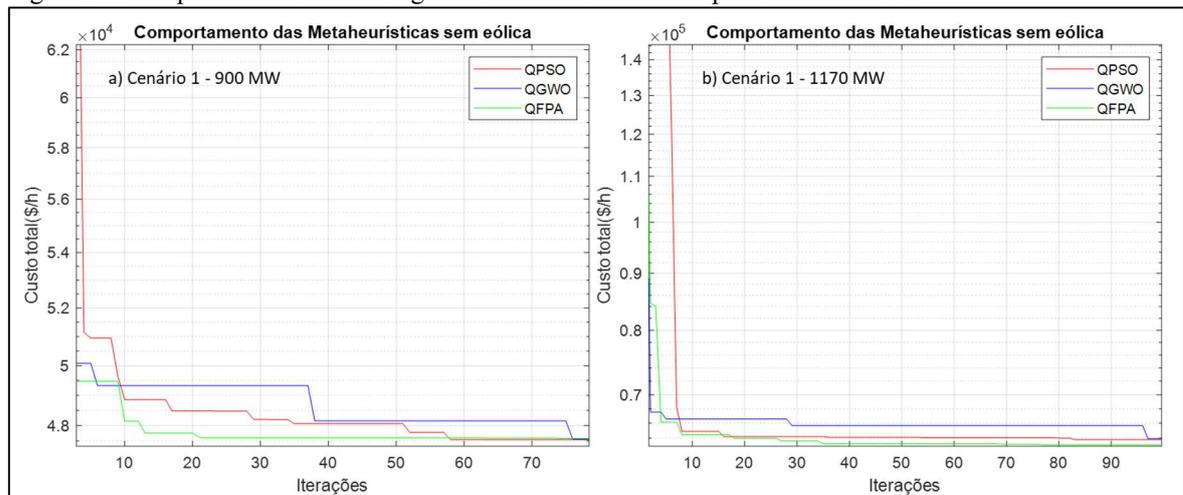
Tabela 7 – Resultados da simulação dos Cenários 1 e 2

Método	Cenário 1			Cenário 2			
	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA	
Geração (MW)	G1	33,01	32,58	34,06	70,22	69,74	73,18
	G2	16,55	10,00	12,93	67,80	68,30	64,82
	G3	149,69	160,94	151,52	250,00	250,00	250,00
	G4	147,04	157,27	149,19	209,97	210,00	210,00
	G5	293,38	262,43	293,98	324,99	325,00	325,00
	G6	298,64	315,00	296,66	315,00	315,00	315,00
Demanda (MW)	900	900	900	1170	1170	1170	
Perdas (MW)	38,319	38,252	38,331	67,984	67,991	67,984	
Delta (MW)	8,10E-04	3,12E-02	4,69E-05	2,45E-04	5,31E-02	1,67E-04	
Custo Econ. (\$/h)	Média	47.413,10	47.669,60	47.331,90	63.739,30	63.576,50	62.945,10
	Desvio	94,92	133,80	1,59	9149,92	312,15	11,40
	Mín.	47.330,40	47.362,30	47.328,90	62.924,20	62.927,80	62.924,60
Custo Amb. (\$/Kg)	Mín.	860,168	864,876	861,989	1.373,46	1.373,56	1.373,62

Fonte: dados da pesquisa (2023).

A Figura 3 ilustra o processo de convergência de cada algoritmo ao longo das iterações.

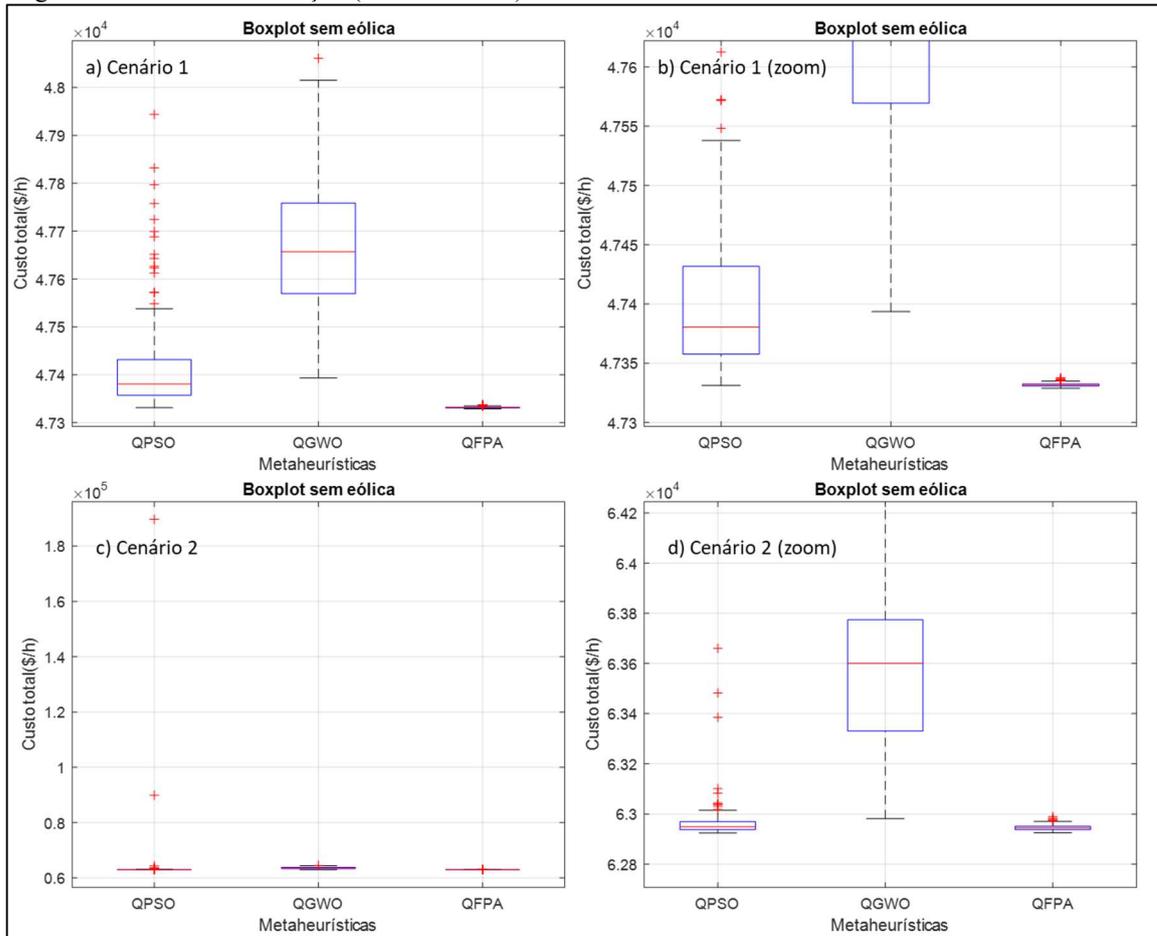
Figura 3 – Comportamento da convergência das meta-heurísticas para Cenários 1 e 2



Fonte: dados da pesquisa (2023).

Com base em 200 execuções realizadas da simulação, os resultados geraram o Box Plot apresentado na Figura 4.

Figura 4 – Box Plot da solução (Cenários 1 e 2)



Fonte: dados da pesquisa (2023).

A Tabela 8 expõe os valores obtidos dos Box Plots, como valor mínimo, valores do 1º e 3º quartil, mediana e *outliers* que são os pontos discrepantes encontrados no processo de repetição da simulação para os dois Cenários.

Tabela 8 – Comparativo valores do Box Plot (Cenários 1 e 2)

Método	Cenário 1			Cenário 2		
	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA
Mínimo	47.331,25	47.393,52	47.328,96	62.924,41	62.980,90	62.924,75
1º Quartil	47.357,59	47.569,31	47.330,82	62.937,70	63.330,97	62.937,26
Mediana	47.380,50	47.657,07	47.331,65	62.948,98	63.600,32	62.944,25
3º Quartil	47.431,73	47.758,66	47.332,51	62.969,17	63.773,65	62.951,07
Máximo	47.943,79	48.060,72	47.337,73	189.660,24	64.521,45	62.989,57
Outliers	15	1	12	13	1	6

Fonte: dados da pesquisa (2023).

4.2.2 Solução do DEA com energia eólica – Sistema 6 geradores

– Cenário 3: demanda 900 MW e Cenário 4: demanda 1.170 MW

Os Cenários 3 e 4 são representados pela simulação do sistema de seis geradores, com energia eólica, com perdas e demanda de 900 e 1.170MW, respectivamente. A princípio, a simulações dos Cenários 3 e 4 é equivalente ao dos Cenários 1 e 2, diferindo apenas na inclusão da energia eólica (1 unidade geradora) na solução do DEA. Os resultados da simulação dos Cenários 3 e 4 são apresentados na Tabela 9.

Tabela 9 – Resultados da simulação dos Cenários 3 e 4

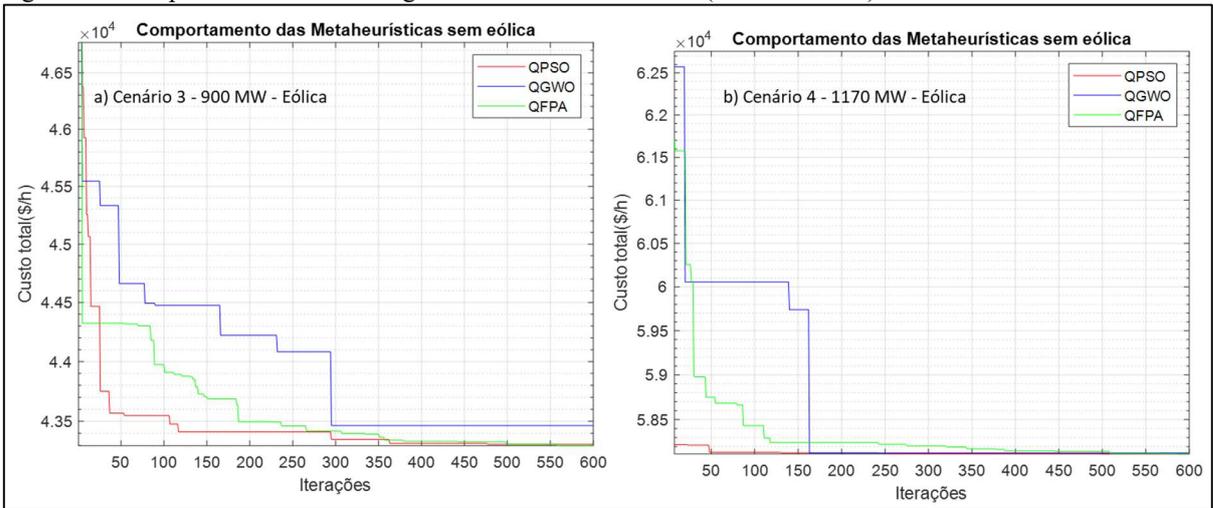
Método	Cenário 3			Cenário 4			
	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA	
Geração (MW)	G1	25,33	17,47	28,44	49,77	44,55	43,39
	G2	11,60	18,36	11,93	26,37	29,80	30,87
	G3	127,22	128,23	137,17	215,22	212,11	223,35
	G4	144,20	120,75	128,91	205,91	210,00	199,22
	G5	272,26	325,00	273,55	324,34	325,00	324,98
	G6	257,84	228,64	258,38	314,87	315,00	314,66
	GW	99,96	100,00	99,98	99,98	100,00	100,00
Demanda (MW)	900	900	900	1170	1170	1170	
Perdas (MW)	38,412	38,409	38,354	66,456	66,444	66,480	
Delta (MW)	1,50E-03	4,16E-02	4,88E-04	1,01E-04	1,46E-02	4,81E-03	
Custo Econ. (\$/h)	Média	43.466,10	43.824,80	43.320,40	58.744,50	58.573,30	58.148,30
	Desvio	392,79	160,96	10,27	7937,53	318,78	15,54
	Mín	43.306,10	43.423,10	43.297,00	58.116,70	58.112,90	58.113,30
Custo Amb. (\$/Kg)	Mín	691,124	729,474	688,942	1223,76	1225,88	1227,88

Fonte: dados da pesquisa (2023).

Destaca-se a parcela de geração associada à usina eólica, que contribuiu no despacho com praticamente 100 MW para todas os algoritmos, ou seja, 100% da capacidade nominal da unidade geradora.

A Figura 5 ilustra o processo de convergência de cada algoritmo ao longo das iterações mediante a inserção da geração eólica no sistema.

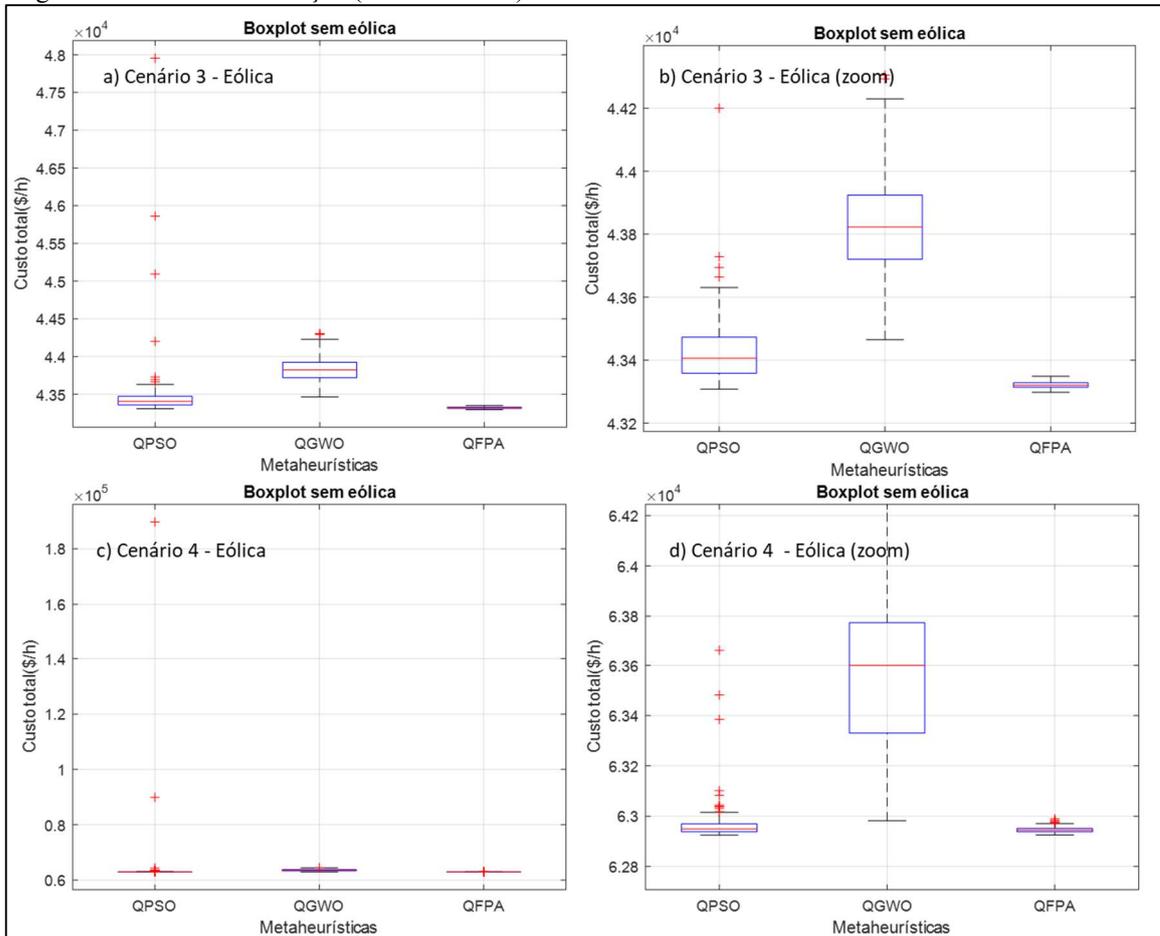
Figura 5 – Comportamento da convergência das meta-heurísticas (Cenários 3 e 4)



Fonte: dados da pesquisa (2023).

O Box Plot comparativo das três meta-heurísticas é apresentado na Figura 6, gerada mediante à execução de 200 simulações de cada meta-heurística, com a geração de distribuição de custos minimizados.

Figura 6 – Box Plot da solução (Cenários 3 e 4)



Fonte: dados da pesquisa (2023).

Na Tabela 10 são fornecidos os principais valores que deram origem ao Box Plot anterior.

Tabela 10 – Comparativo dos valores do Box Plot (Cenários 3 e 4)

Método	Cenário 3			Cenário 4		
	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA
Mínimo	43.307,58	43.464,70	43.297,49	58.116,75	58.127,51	58.118,10
1° Quartil	43.358,19	43.720,38	43.313,65	58.145,41	58.367,89	58.138,19
Mediana	43.406,01	43.822,68	43.320,08	58.169,01	58.484,08	58.147,25
3° Quartil	43.473,02	43.924,50	43.327,72	58.197,72	58.696,16	58.157,03
Máximo	47.953,82	44.305,28	43.348,48	170.433,36	60.872,00	58.218,84
Outliers	7	2	0	16	7	3

Fonte: dados da pesquisa (2023).

4.2.3 Solução do DEA sem energia eólica – Sistema 14 geradores

– Cenário 5: demanda 1750 MW e Cenário 6: demanda 2650 MW

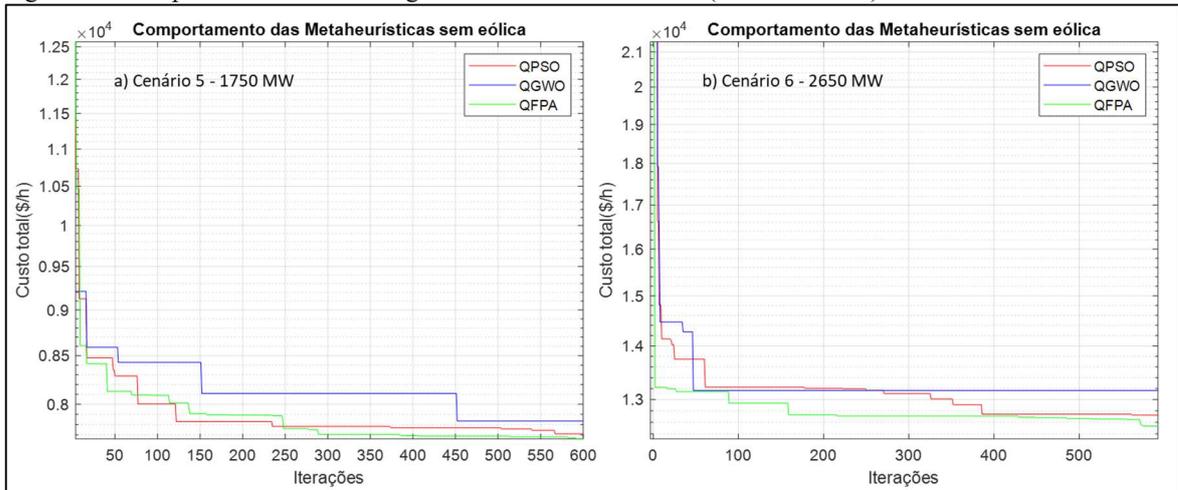
O sistema de 14 geradores foi simulado sem energia eólica, sem perdas e com dois Cenários de carga, 1.750 MW e 2.650 MW, correspondendo aos Cenários 5 e 6, respectivamente. A Tabela 11 apresenta o resultado destas simulações:

Tabela 11 – Resultados da simulação dos Cenários 5 e 6

Método	Cenário 5			Cenário 6			
	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA	
Geração (MW)	G1	279,59	297,22	247,16	326,01	407,32	427,49
	G2	214,55	250,63	236,76	431,98	437,67	385,64
	G3	57,05	24,59	67,42	125,55	118,85	117,49
	G4	109,63	130,00	125,39	106,58	130,00	111,96
	G5	208,48	150,00	186,16	382,61	347,01	291,42
	G6	182,53	135,00	149,83	325,95	135,00	301,56
	G7	142,58	135,00	146,40	169,01	393,56	227,23
	G8	68,68	60,00	85,69	238,92	194,20	204,48
	G9	126,86	160,00	141,23	152,59	152,76	151,31
	G10	132,99	153,99	157,09	158,00	160,00	156,15
	G11	75,68	80,00	66,91	72,65	38,13	63,32
	G12	80,00	53,99	76,56	78,39	47,72	78,87
	G13	27,17	64,75	32,86	26,76	72,83	78,34
	G14	44,20	55,00	30,54	55,00	15,00	54,76
Demanda (MW)	1750	1750	1750	2650	2650	2650	
Delta (MW)	1,51E-02	1,60E-01	5,28E-03	8,21E-03	4,13E-02	1,10E-02	
Custo Econ. (\$/h)	Média	8.022,28	8.287,84	7.753,80	54.270,50	14.049,60	12.704,20
	Desvio	164,96	176,49	41,42	91.986,10	343,76	71,24
	Mín.	7.694,92	7.673,56	7.655,69	12.716,70	13.123,50	12.524,00
Custo Amb. (\$/Kg)	Mín.	3.108,24	3.419,55	3.033,24	10.740,20	11.757,20	9.554,16

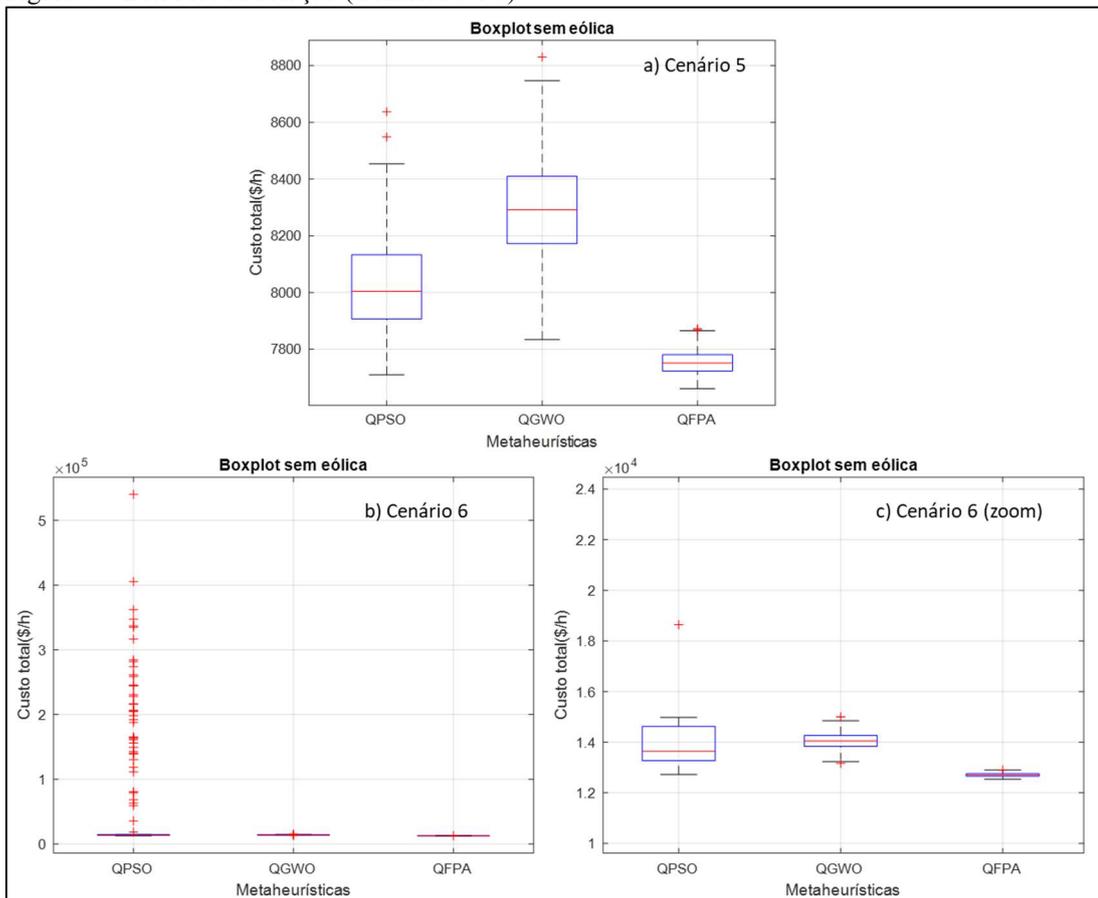
Fonte: dados da pesquisa (2023).

Figura 7 – Comportamento da convergência das meta-heurísticas (Cenários 5 e 6)



Fonte: dados da pesquisa (2023).

Figura 8 – Box Plot da solução (Cenários 5 e 6)



Fonte: dados da pesquisa (2023).

A Figura 7 ilustra o processo de convergência de cada algoritmo ao longo das iterações. O Box Plot apresentado na Figura 8 revela o comparativo de resultados obtidos mediante simulação de 200 vezes cada algoritmo.

Apresenta-se, na Tabela 12, o resumo dos principais resultados geradores do Box Plot acima, com os valores mínimos, máximos e quartis, além de valores discrepantes (*outliers*).

Tabela 12 – Comparativo valores do Box Plot (Cenários 5 e 6)

Método	Cenário 5			Cenário 6		
	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA
Mínimo	7.709,99	7.833,83	7.660,97	12.724,88	13.164,72	12.535,06
1° Quartil	7.906,55	8.172,45	7.723,15	13.267,17	13.830,64	12.655,54
Mediana	8.004,36	8.291,71	7.751,15	13.645,25	14.051,95	12.696,72
3° Quartil	8.132,78	8.409,97	7.780,82	14.621,17	14.267,78	12.752,85
Máximo	8.637,23	8.830,41	7.872,27	540.235,50	15.005,93	12.901,00
Outliers	2	1	2	43	3	1

Fonte: dados da pesquisa (2023).

4.2.4 Solução do DEA com energia eólica – Sistema 14 geradores

– Cenário 7: demanda 1.750 MW e Cenário 8: demanda 2.650

As simulações dos Cenários 7 e 8 dizem respeito ao sistema de 14 geradores considerando energia eólica, sistema sem perdas e cargas de 1.750 e 2.650 MW, respectivamente. Os resultados da simulação dos Cenários 7 e 8 são apresentados na Tabela 13.

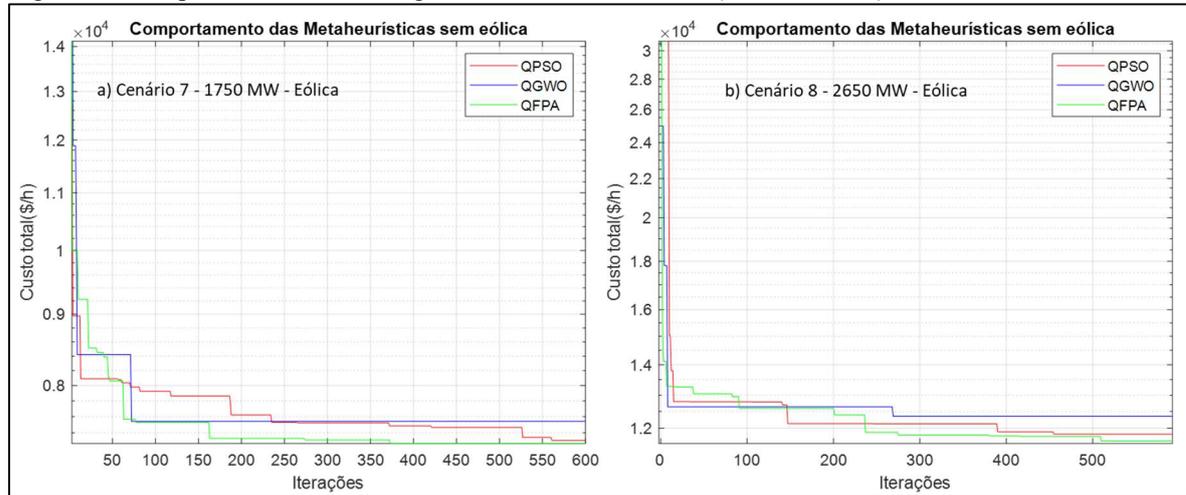
Tabela 13 – Resultados da simulação dos Cenários 7 e 8

Método	Cenário 7			Cenário 8			
	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA	
Geração (MW)	G1	199,09	150,00	190,23	431,92	455,00	383,59
	G2	210,29	239,49	221,95	455,00	413,54	388,97
	G3	22,10	123,94	30,20	74,67	59,13	125,50
	G4	78,89	24,57	34,80	103,76	44,06	115,51
	G5	153,86	159,60	157,82	219,54	470,00	165,71
	G6	176,42	135,00	165,12	259,69	135,00	185,20
	G7	139,95	135,00	135,00	135,00	135,00	135,00
	G8	63,99	152,41	65,65	188,80	213,30	261,48
	G9	92,63	160,00	103,67	138,59	80,60	158,28
	G10	146,62	25,00	124,74	159,17	160,00	160,00
	G11	43,83	80,00	73,68	65,94	38,30	77,94
	G12	49,84	54,49	68,96	80,00	80,00	77,77
	G13	46,93	31,12	53,11	32,84	51,08	75,26
	G14	31,16	15,00	32,84	15,90	15,00	51,76
GW1	94,41	97,81	99,99	92,95	100,00	100,00	
GW2	100,00	100,00	99,34	100,00	100,00	96,69	
GW3	100,00	66,56	92,93	96,24	100,00	91,38	
Demanda (MW)	1750	1750	1750	2650	2650	2650	
Delta (MW)	1,24E-02	2,23E-02	3,77E-02	1,21E-02	7,16E-02	3,19E-02	
Custo Econ. (\$/h)	Média	7.740,40	8.126,25	7.467,93	60.145,50	13.664,40	11.923,80
	Desvio	181,12	248,30	88,60	81958,70	419,59	93,85
	Mín.	7.292,20	7.518,27	7.231,92	11.816,50	12.282,10	11.597,50
Custo Amb. (\$/Kg)	Mín.	2.085,54	2.575,38	2.179,25	9.928,31	11.648,80	7.813,24

Fonte: dados da pesquisa (2023).

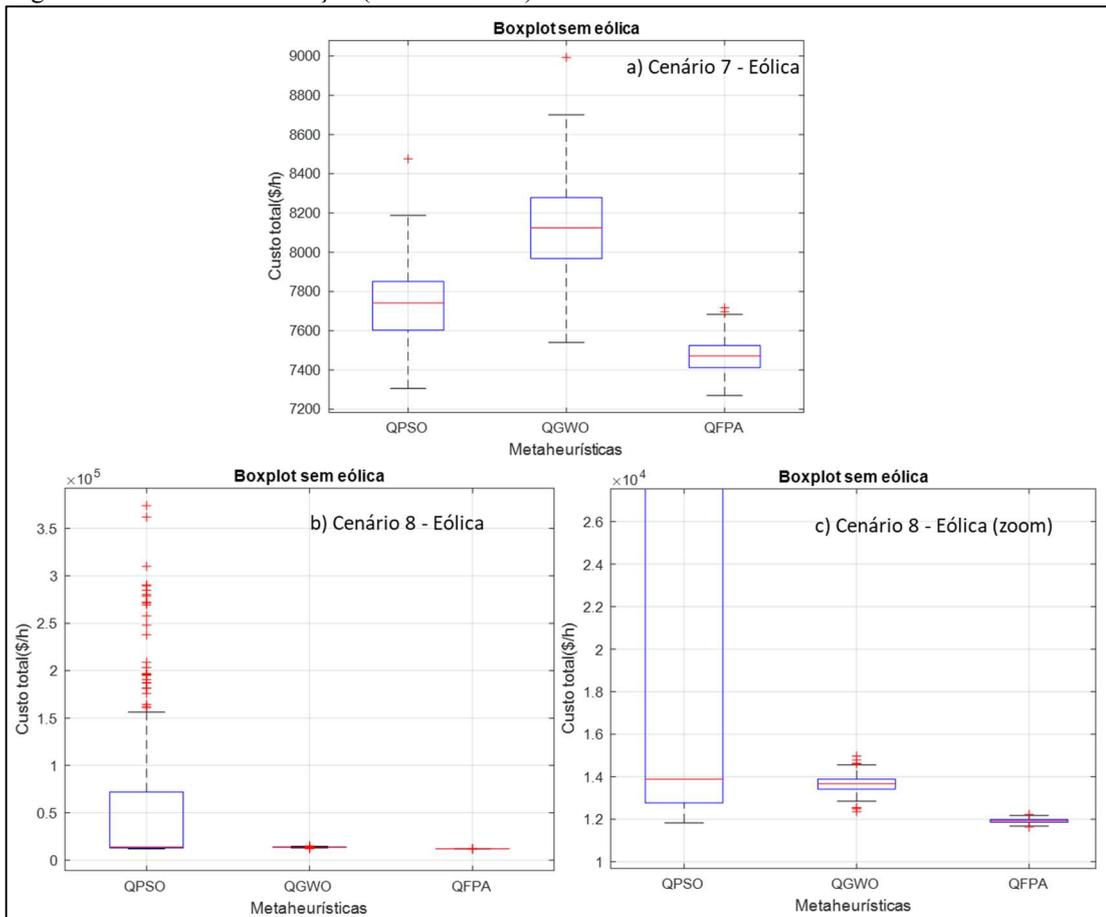
O processo de minimização de cada meta-heurística é apresentado na Figura 9, e ilustra o processo de convergência ao longo das iterações.

Figura 9 – Comportamento da convergência das meta-heurísticas (Cenários 7 e 8)



Fonte: dados da pesquisa (2023).

Figura 10 – Box Plot da solução (Cenários 7 e 8)



Fonte: dados da pesquisa (2023).

Na Figura 10, o Box Plot comparativo das três meta-heurísticas é apresentado, mediante 200 simulações de cada uma. Os resultados puderam gerar uma distribuição de custos minimizados.

Na Tabela 14 são sumarizados os resultados centrais do Box Plot anterior, incluindo os valores mínimos, máximos, quartis e quantidade de valores discrepantes.

Tabela 14 – Comparativo valores do Box Plot (Cenários 7 e 8)

Método	Cenário 7			Cenário 8		
	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA
Mínimo	7.305,57	7.540,59	7.269,61	11.828,57	12.353,70	11.629,40
1° Quartil	7.602,85	7.967,80	7.411,72	12.765,74	13.411,04	11.854,33
Mediana	7.740,98	8.124,91	7.470,77	13.886,89	13.666,94	11.923,16
3° Quartil	7.851,25	8.278,59	7.524,30	72.022,78	13.889,03	11.983,72
Máximo	8.475,39	8.992,50	7.716,84	374.178,73	14.970,04	12.228,12
Outliers	1	1	2	28	8	2

Fonte: dados da pesquisa (2023).

4.3 Discussão dos resultados

Esta seção apresenta a análise dos dados encontrados na presente pesquisa, que foram mostrados no tópico anterior. Para se efetivar a análise e chegar a uma conclusão, considerou-se, com métrica, os valores obtidos nos resultados dos custos econômicos médios, mínimos e desvio-padrão, bem como valores estatísticos, como mediana, quartis e quantidade de valores discrepantes, gerados pelas 200 simulações realizados para cada algoritmo, onde foi possível obter os gráficos estatísticos

Destaca-se que nas simulações, com base da Equação 8, o δ considerado foi 1, desta forma as emissões de poluentes foram desprezadas no processo de otimização, tornando apenas o custo econômico como parâmetro determinante para a avaliação do desempenho das meta-heurísticas.

Para avaliar o impacto da energia eólica na redução das emissões de gases na atmosfera e nos custos operacionais de produção de energia, conduziu-se uma análise comparativa. Inicialmente, examinou-se a quantidade de emissões geradas e custos pelo sistema de energia sem a integração das usinas eólicas. Posteriormente, essa análise foi repetida após a inclusão das unidades eólicas. O propósito dessa implementação foi evidenciar o papel da energia eólica no contexto ambiental, destacando a sua contribuição na redução de poluentes, além de seu impacto na redução dos custos econômicos de operação do sistema.

De forma geral, o algoritmo QFPA demonstrou consistência nos resultados em diversos Cenários de demanda energética, e presença ou ausência de energia eólica. Em

comparação com outras abordagens, como QGWO e QPSO, o QFPA exibiu menor dispersão e maior precisão.

Sendo mais específico, de acordo com a Tabela 7, onde traz o comparativo entre os Cenários 1 e 2 (sistema seis geradores com cargas 900 e 1.170 MW sem geração eólica) o QFPA apresentou as menores médias de custo e desvio-padrão, sendo que para o Cenário 1 os valores foram: 47.331,90 \$/h, 1,59 \$/h. De forma análoga, o Cenário 2 teve os seguintes valores: 62.945,10 \$/h, 11,40 \$/h. Observa-se que o acréscimo de demanda do Cenário 1 para 2 provocou uma elevação do desvio-padrão de 617% para o QFPA. Além disso, verificou-se que para todos os algoritmos o custo mínimo teve um crescimento de 33% com a mudança de Cenário 1 para 2.

Os resultados obtidos para os Cenários 1 e 2 convergem com o estudo desenvolvido por Bayon *et al.* (2012), onde foi aplicado uma metodologia de solução analítica exata para o DEA aplicado aos mesmos sistemas. De acordo com o autor, o custo econômico mínimo obtido para seu melhor método, foi de 47.329,30 \$/h para o cenário 1, enquanto neste trabalho foi encontrado 47.328,90 \$/h para o QFPA, resultado ligeiramente melhor. Já para o cenário 2, a mesma literatura aponta resultado de 62.923,51 \$/h, contra 62.924,60 \$/h deste estudo, resultado maior, porém muito próximo.

Na Figura 3, o comportamento de otimização ao longo das iterações foi apresentado para cada meta-heurística. Verificou-se que o QFPA obteve um comportamento mais contundente em busca do menor valor de custo econômico para os dois Cenários.

A Figura 4 ilustra o Box Plot para os Cenários 1 e 2. Observa-se que o QFPA obteve melhor resultado em termos de precisão e exatidão, enquanto o QGWO teve os resultados mais dispersos. A Tabela 8 corrobora com a análise da Figura 4, pois é possível inferir que o QFPA possui a menor dispersão, dada a minimização dos valores do 1º e 3º quartil quando comparados aos outros algoritmos. O QFPA também possui a melhor simetria, onde a mediana é a menor e mais centralizada no intervalo interquartil em relação aos outros. O algoritmo com pior desempenho foi o QGWO, apesar de ter apresentado apenas um valor discrepante (*outliers*) para os Cenários 1 e 2.

Para os Cenários 3 e 4, representados pelos sistemas de seis geradores com energia eólica, para as cargas de 900 e 1.170 MW, respectivamente, a Tabela 9 expõe os resultados dessa simulação. É possível notar que o QGWO obteve o menor custo econômico mínimo dentre os algoritmos, mas apresentou desvio e média de custo elevados. Por outro lado, o QFPA, para o Cenário 3 apresentou um desvio e média de custo de 10,27 \$/h e 43.42040 \$/h, respectivamente, e para o Cenário 4 um desvio de 15,54 \$/h e custo médio de 58.148,30 \$/h, se

sobressaindo perante os outros. O QPSO obteve os piores resultados, principalmente por conta do desvio de 7.937,53 \$/h no Cenário 4. Destaca-se que a mudança de carga de um cenário para outro gerou um aumento de custo econômico na ordem de 34% para todas as meta-heurísticas. Outro ponto que vale frisar na Tabela 9 é o valor de delta, que para o QFPA é o menor valor, $4,69 \times 10^{-5}$ e $1,67 \times 10^{-4}$, Cenários 3 e 4, respectivamente, mostrando que a aderência ao atendimento do balanço de potência foi mais evidente.

Ressalta-se, ainda, a parcela de geração associada à usina eólica, que contribuiu no despacho com praticamente 100 MW para todas os algoritmos, ou seja, 100% da capacidade nominal da unidade geradora. A contribuição da geração eólica foi crucial para redução dos custos médios econômicos em relação aos Cenários sem energia eólica, na ordem de 8,3% e 7,6%, para os Cenários 3 e 4, respectivamente.

Na Figura 5, o processo de otimização do custo econômico de cada meta-heurística é apresentado. Nota-se que, para os Cenários 3 e 4, o QPSO tentou mais rapidamente se aproximar da minimização ótima, porém, devido ao valor elevado do custo obtido na primeira iteração, evidenciado pelos valores máximos da Tabela 10, o QPSO não teve o melhor desempenho, o que tornou os desvios maiores dos que as técnicas concorrentes, para os Cenários 3 e 4, de acordo com Tabela 9.

Mediante as 200 simulações realizadas para cada algoritmo, foi possível gerar a análise estatística, como demonstra a Figura 6. Nota-se, que o QFPA, mesmo com a inserção da energia eólica no sistema, se apresentou mais compactado e com menores resultados, o que se permite concluir que o método foi o mais preciso e exato para a solução do DEA para os Cenários 3 e 4.

É possível verificar, com base na Tabela 10, que o QFPA possui a menor dispersão para os Cenários 3 e 4, pois a diferença entre os valores do 1º e 3º quartil é menor, quando comparado aos outros algoritmos. O QFPA também possui a melhor simetria, onde as medianas são as menores e mais centralizadas no intervalo interquartil em relação aos outros. O algoritmo com pior desempenho foi o QPSO, apresentando mais valores discrepantes (*outliers*), e maiores valores máximos do custo econômico, de 47.953,82 e 170.433,36 \$/h, fazendo com o que os desvios fossem muito altos também para essa meta-heurística.

Para os Cenários 5 e 6, o sistema de 14 geradores foi simulado para as demandas de 1.750 e 2.650 MW, ambos desconsiderando a geração de energia eólica e as perdas. A Tabela 11 expõe os resultados da simulação. É possível notar que nos dois Cenários (5 e 6) o QFPA apresentou o melhor resultado para custo médio, desvio e custo mínimo. O acréscimo de carga

de 1.750 para 2.650 MW proporcionou ao QFPA um aumento de 64% no custo mínimo e 72% no desvio-padrão.

Os resultados para cenário 5 e 6 podem ser comparados com Gherbi, Bouzeboudja e Gherbi (2016). Os autores implementaram a solução do DEA no sistema de 14 geradores com perdas e obtiveram como melhor resultado o custo econômico de 7.821,23 \$/h e 13.279,53 \$/h, para as demandas de 1750 e 2650 MW, respectivamente. Os resultados corroboram com os obtidos nesse estudo, onde se obteve, para as mesmas cargas e sistema, 7.655,69 \$/h e 12.524,00 \$/h para custo econômico mínimo do QFPA.

Representando a evolução da otimização de cada meta-heurística ao longo das iterações, a Figura 7 ilustra tal comportamento. Observa-se que o QFPA tende a minimizar mais rapidamente a função objetivo.

Com relação ao Box Plot ilustrado pela Figura 8 e resultados apresentados na Tabela 12, observa-se que o QFPA obteve melhor desempenho para os Cenários 5 e 6. É possível notar que o QFPA possui a menor dispersão, possui a melhor simetria, onde a mediana é a menor e mais centralizada no intervalo interquartil, para os dois Cenários (5 e 6). O QGWO obteve pior resultado no Cenário 5, apesar de ter apenas um valor discrepante. O QPSO, no Cenário 6, obteve pior desempenho seguido dos 43 *outliers*.

Para os Cenários 7 e 8, que correspondem à simulação do sistema de 14 geradores, sem perdas e com energia eólica, para dois volumes de carga, 1.750 e 2.650 MW, respectivamente, a Tabela 13 apresenta os resultados da simulação. Verifica-se que os melhores resultados foram do QFPA. A mudança de cenário pela elevação da carga provocou aumento no custo médio do QPSO de 677%, enquanto o QFPA cresceu apenas 60%. Essa mesma comparação, relacionada com o desvio-padrão, resultou em crescimento de 45,152% para o QPSO e 6% para o QFPA.

É importante evidenciar a contribuição da geração eólica, em que as três usinas operaram acima de 90% da sua capacidade nominal, com exceção da usina 3, no Cenário 7, para o QGWO, que gerou apenas 66,56 MW. Pode-se inferir, com base na Tabela 13, que a geração eólica favoreceu para redução do custo mínimo. Essa redução média para os algoritmos foi de aproximadamente 4,3% para o Cenário 7 em relação ao Cenário 5, e 7% para o Cenário 8 em relação ao Cenário 6.

A Figura 9 mostra o desempenho de cada meta-heurística relacionado com o processo de minimização. Nota-se que o melhor desempenho obtido foi do QFPA, pois apesar de não conseguir o melhor resultado nas primeiras iterações, o mesmo se sobressai ao longo das mesmas.

Na Figura 10 observa-se a análise estatística de cada simulação dos Cenários 7 e 8. Os resultados são mais aproximados no Cenário 7, porém, no Cenário 8, com aumento de carga, observa-se resultados mais dispersos, principalmente para QPSO. Essa dispersão pode ser constatada na Tabela 14, onde apresenta os valores referência dos Box Plots. Nota-se o valor máximo do QPSO para o Cenário 8 de 374.178,73 \$/h, extremamente elevado em relação aos concorrentes, seguido de 28 valores discrepantes, justificando o baixo desempenho do algoritmo. Por outro lado, QFPA apresentou resultados mais próximos, desde valores máximos, mínimos e quartis, justificando a melhor simetria e menor dispersão entre os concorrentes.

Em resumo, infere-se, com base nos resultados, que o aumento da carga e número de geradores do sistema tornou o processo de otimização mais complexo. Tal situação é justificada pelo aumento dos custos mínimos, médios e desvios encontrados, assim como os Box Plots também apresentaram maior dispersão, com aumento de valores discrepantes para todos os algoritmos. Isso mostra que o aumento de carga entre Cenários dificulta o processo de convergência dos algoritmos. Esse resultado é evidenciado também no estudo desenvolvido por Jiang, Ji e Wang (2015), onde o DEA foi solucionado utilizando o algoritmo PSO otimizado, primeiramente em um sistema de seis geradores com 283 MW, e em seguida em um sistema de 40 geradores com carga de 10.500 MW. Para o custo econômico, os valores médio e desvio aumentaram 201% e 76,874%, respectivamente, devido ao aumento de carga e complexidade do sistema.

Vale ressaltar que a geração eólica em todos os Cenários foi determinante para redução dos custos de geração e emissão de poluentes. Estudos realizados por Ghasemi et al. (2016) e Martins (2020) corroboram com essa abordagem, indicando o impacto da integração de geração eólica para redução dos custos de produção de energia e redução da emissão de poluentes.

Como já mencionado, de forma geral, neste estudo, o QFPA se sobressaiu perante as outras meta-heurísticas, como pode ser visto na Tabela 15, onde é apresentado um panorama dos resultados obtidos para cada Cenário e para cada meta-heurística. O sinal “+” representa que o resultado obtido para um determinado item foi o melhor entre as meta-heurísticas comparadas; já o sinal de “--” indica o pior resultado. Percebe-se que o QFPA obteve a maior parte dos sinais de positivos, o que demonstra o melhor desempenho simulado.

Tabela 15 – Panorama comparativo de resultados dos Cenários

Custo Econômico \$/h	Cenário 1			Cenário 2			Cenário 3			Cenário 4		
	QPSO	GWO	QFPA	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA
Média	-	--	+	--	-	+	-	--	+	--	-	+
Desvio	-	--	+	--	-	+	--	-	+	--	-	+
Mínimo	-	--	+	+	--	-	-	--	+	--	+	-
Custo Econ. \$/h	Cenário 5			Cenário 6			Cenário 7			Cenário 8		
	QPSO	GWO	QFPA	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA	QPSO	QGWO	QFPA
Média	-	--	+	--	-	+	-	--	+	--	-	+
Desvio	-	--	+	--	-	+	-	--	+	--	-	+
Mínimo	-	--	+	-	--	+	-	--	+	-	--	+

Fonte: dados da pesquisa (2023).

Não foram encontrados na literatura estudos de aplicação do QFPA para solução do DEA com e sem energia eólica para evidenciar esta superioridade. Entretanto, Costa Filho (2023) realizou um estudo com a aplicação do QFPA em comparação a outras meta-heurísticas para solução de problema de sintonização de estabilizadores em sistemas de potência, realizados em quatro sistemas elétricos distintos, sendo: 5 geradores-10 barras, 10 geradores-39 barras, 50 geradores-615 barras e 170 geradores-3584 barras.

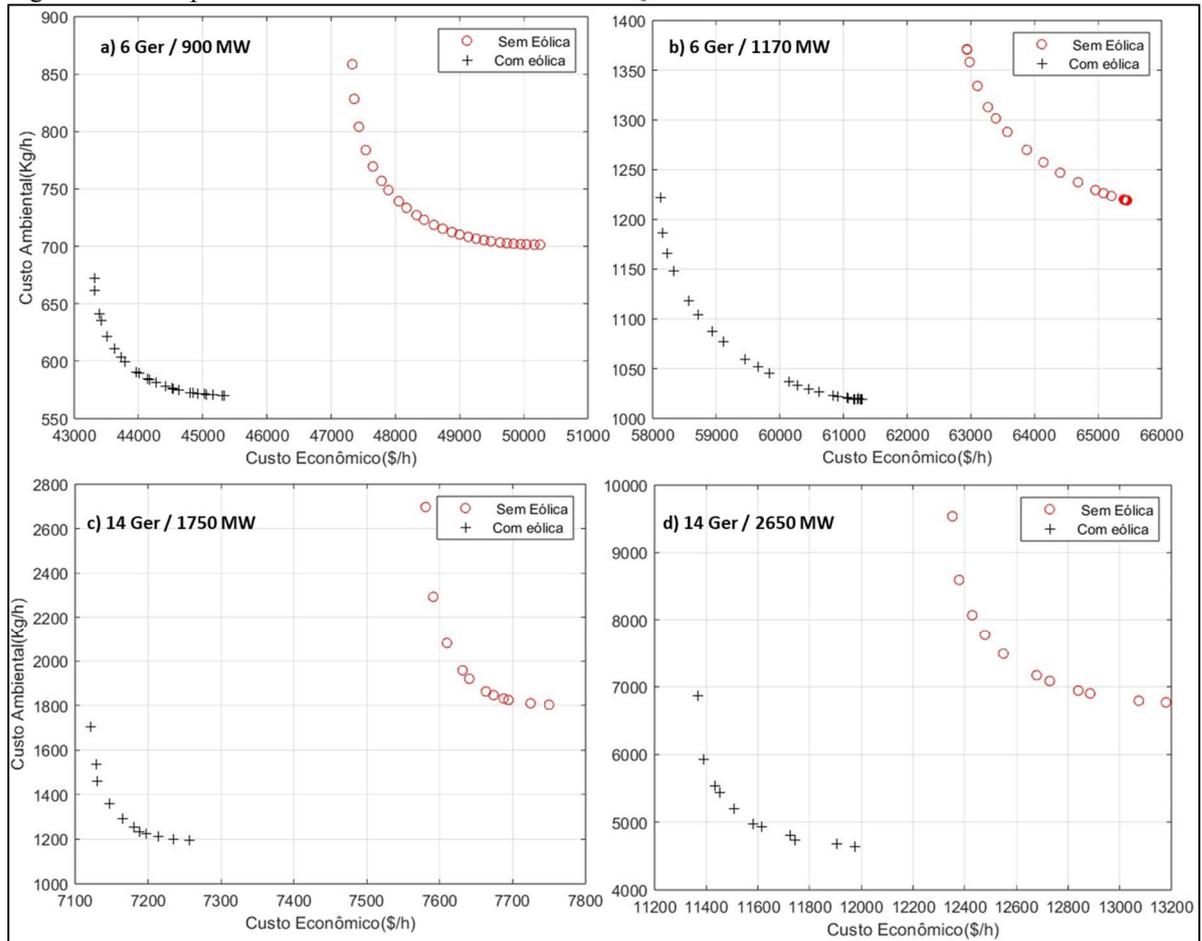
Os resultados deste estudo revelaram que o QFPA obteve os melhores resultados, em todos os índices, para o sistema mais complexo, o de 170 geradores, o que reforça a possibilidade de uso do QFPA neste estudo e em outras aplicações futuras.

4.4 Análise da Curva de Pareto

A curva de fronteira de Pareto foi gerada tanto para os sistemas de seis quanto para o sistema de 14 geradores, utilizando o algoritmo com melhor desempenho nas simulações anteriores, o QFPA.

Para o sistema de seis geradores, a curva foi obtida considerando o sistema com perdas, sem e com energia eólica para as demandas de 900 e 1.170 MW. Já para o sistema de 14 geradores, os Cenários simulados foram sem perdas, sem e com energia eólica, e para as demandas de 1.750 e 2650 MW. A Figura 11 apresenta os comparativos das curvas entre os sistemas e Cenários.

Figura 11 – Comparativo de curva de Fronteira de Pareto QFPA



Fonte: dados da pesquisa (2023).

As curvas expressam os conflitos entre dois objetivos-alvo do problema DEA, ou seja, não é possível minimizar um dos objetivos sem aumentar o outro. É importante destacar a contribuição significativa da geração eólica no processo de otimização, pois há significativas reduções dos pontos de utopia e ponto de compromisso, conforme abordado no tópico 2.4 e Figura 1, bem como as distâncias euclidianas entre os pontos, com relação ao cenário sem geração eólica.

Percebe-se que com o aumento da carga do sistema, a curva de Pareto tem uma maior amplitude em relação ao custo econômico, e os resultados mostram um maior custo econômico para geração de energia. A tendência é que com o aumento de carga, haja redução do número de soluções não dominadas, ou seja, o número de pontos da curva de Pareto vai reduzindo, e o espaçamento entre os pontos aumentando.

5 CONCLUSÃO E SUGESTÃO DE TRABALHOS FUTUROS

Neste trabalho foram aplicadas meta-heurísticas quânticas bioinspiradas para solução do despacho econômico ambiental com energia eólica como problema multiobjetivo, ou seja, com dois objetivos conflitantes. Os métodos de otimização foram inspirados no comportamento quântico das partículas de enxame (QPSO), comportamento quântico dos lobos cinzentos (QGWO) e no comportamento quântico da polinização das flores (QFPA). Dois sistemas elétricos com diferentes números de geradores e Cenários de carga, bem como inclusão de geração eólica, foram submetidos à aplicação das meta-heurísticas.

A análise realizada comparou o desempenho destas meta-heurísticas quânticas, e os resultados revelaram que o QFPA de forma geral superou os outros dois algoritmos em termos de precisão, eficácia e estabilidade na otimização dos custos econômicos e ambientais, mantendo-se consistente em diferentes Cenários de demanda e configurações do sistema. O QFPA demonstrou menor desvio-padrão e menor média de custo, refletindo uma convergência mais rápida para soluções ótimas e menor sensibilidade às variações nos parâmetros do problema.

Além disso, a inclusão da geração de energia eólica nos sistemas mostrou benefícios significativos na redução dos custos econômicos e ambientais, destacando-se como uma estratégia viável para melhorar a eficiência e a sustentabilidade dos sistemas de geração de energia elétrica.

Assim, os resultados demonstram que o QFPA pode ser uma escolha viável para resolver problemas complexos de otimização em sistemas de energia elétrica, especialmente quando se considera a integração de fontes renováveis, como a energia eólica. O resultado deste trabalho tem o potencial de oferecer perspectivas valiosas para o planejamento e a operação otimizados de redes elétricas durante a transição para uma matriz energética mais limpa e sustentável.

Para trabalhos futuros, sugere-se a abordagem dos seguintes temas:

- Análise do DEA com economia de baixo carbono;
- Aplicação de novas meta-heurísticas na solução do problema DEA;
- Aplicação do QFPA para solução do DEA em sistemas mais complexos.

REFERÊNCIAS

- ABDELAZIZ, A. Y.; ALI, E. S.; ABD ELAZIM, S. M. Implementation of flower pollination algorithm for solving economic load dispatch and combined economic emission dispatch problems in power systems. **Energy**, [S. l.], v. 101, p. 506-518, 2016.
- BASAK, S.; DEY, B.; BHATTACHARYYA, B. Demand side management for solving environment constrained economic dispatch of a microgrid system using hybrid MGWOSCACSA algorithm. **CAAI Transactions on Intelligence Technology**, [S. l.], v. 7, n. 2, p. 256-267, 2022.
- BAYON, L. *et al.* The Exact Solution of the Environmental/Economic Dispatch Problem. **IEEE Transactions on Power Systems**, [S. l.], v. 27, n. 2, p. 723-731, 2012.
- BICHELS, A. **Sistemas Elétricos De Potência: Métodos De Análise E Solução**. EDUTFPR, 2019.
- BIGOT, P. G. **Abordagem de Pareto para a Otimização Multiobjetivo do Desempenho de um Controlador SDRE Aplicado a um sistema não linear**. [S. l.], 2015. (Dissertação de Mestrado em Engenharia e Tecnologia Espaciais/Mecânica Espacial e Controle – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.
- BRITO JÚNIOR, J. A. **Solução para o despacho econômico ambiental de um sistema de geração térmica por recozimento simulado**. 2018. 125 f. Tese (Doutorado em Engenharia Elétrica) – Instituto de Tecnologia, Universidade Federal do Pará, Belém, 2018.
- COSTA FILHO, R. N. D. Comparative study of three quantum-inspired optimization algorithms for robust tuning of power system stabilizers. **Neural Computing and Applications**, [S. l.], v. 35, n. 17, p. 12905-12914, 2023.
- DAMODARAN, S.; KUMAR, T. S. Hydro-Thermal-Wind Generation Scheduling Considering Economic and Environmental Factors Using Heuristic Algorithms. **Energies (Basel)**, [S. l.], n. 11, v. 2, 2018.
- ELATTAR, E. E. (2019). Environmental economic dispatch with heat optimization in the presence of renewable energy based on modified shuffle frog leaping algorithm. **Energy**, Oxford, v. 171, p. 256-269, 2019.
- FILHO, R. N. D. C. **Controle robusto e coordenado de estabilizadores de sistemas de potência utilizando sinais remotos com vista à estabilidade angular dos sistemas de energia elétrica**. 2018. 176f. Tese (Programa de Pós-Graduação em Engenharia de Eletricidade/CCET) - Universidade Federal do Maranhão, São Luís. 2018.
- GHASEMI, A. *et al.* Modeling of Wind/Environment/Economic Dispatch in power system and solving via an online learning meta-heuristic method. **Applied Soft Computing**, [S. l.], v. 43, p. 454-468, 2016.
- GHERBI, Y. A.; BOUZEBOUDJA, H.; GHERBI, F. Z. The combined economic environmental dispatch using new hybrid metaheuristic. **Energy**, [S. l.], v. 115, p. 468-477,

2016.

GLOVER, F.; SÖRENSEN, K. Metaheuristics. **Scholarpedia**, [S. l.], n. 10, v. 4, p. 6532, 2015.

GOMEZ-EXPOSITO, A.; CONEJO, A. J.; CANIZARES, C. **Electric energy systems: analysis and operation**. CRC press, 2009.

GUO, F. *et al.* Distributed Economic Dispatch for Smart Grids With Random Wind Power. **IEEE Transactions on Smart Grid**, [S. l.], v. 7, n. 3, p. 1572-1583, 2016.

HABIBI, F. *et al.* Simultaneous multi-area economic-environmental load dispatch modeling in presence of wind turbines by MOPSO. **Journal of Electrical Engineering & Technology**, [S. l.], v. 15, n. 3, p. 1059-1072, 2020.

HAGH, M. T.; KALAJAHI, S. M. S.; GHORBANI, N. Solution to economic emission dispatch problem including wind farms using Exchange Market Algorithm Method. **Applied Soft Computing**, [S. l.], v. 88, 2020.

HETZER, J.; DAVID, C. Y.; BHATTARAI, K. An economic dispatch model incorporating wind power. **IEEE Transactions on energy conversion**, [S. l.], v. 23, n. 2, p. 603-611, 2008.

INTERNATIONAL ENERGY AGENCY – IEA. **Electricity Market Report 2023**, 2023. Disponível em: <https://www.iea.org/reports/electricity-market-report-2023>. Acesso em: 5 jan. 2024.

JADHAV, H. T.; ROY, R. Gbest guided artificial bee colony algorithm for environmental/economic dispatch considering wind power. **Expert Systems with Applications**, [S. l.], v. 40, n. 16, p. 6385-6399, 2013.

JIANG, S.; JI, Z.; WANG, Y. A novel gravitational acceleration enhanced particle swarm optimization algorithm for wind-thermal economic emission dispatch problem considering wind power availability. **International Journal of Electrical Power and Energy Systems**, [S. l.], 2015.

KUO, C. C. Wind energy dispatch considering environmental and economic factors. **Renew. Energy**, [S. l.], v. 35, n. 10, p. 2217-2227, 2010.

LI, Y. Z. *et al.* Risk Constrained Economic Dispatch with Integration of Wind Power by Multi-objective Optimization Approach. **Energy**, Oxford, v. 126, p. 810-820, 2017.

LIU, X.; XU, W. **Minimum Emission Dispatch Constrained by Stochastic Wind Power Availability and Cost**. Power Systems, IEEE Transactions on. 25. 2010.

LU, K.; LI, H. Quantum-Behaved Flower Pollination Algorithm. **14th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES)**, Guiyang, China, 2015.

MARTINS, A. C. S. **Métodos de otimização multiobjetivo em problemas de despacho econômico e ambiental de sistemas termo-eólicos**. 2020. 155 f. Tese (Doutorado em

Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Bauru, 2020.

MATLAB, versão: 9.13. 0 (R2022b), Natick, Massachusetts: The MathWorks Inc.; 2022

MIRJALILI, S.; MIRJALILI, S. M.; LEWIS, A. Grey Wolf Optimizer. **Advances in Engineering Software**, [S. l.], v. 69, 2014.

MONDAL, S.; BHATTACHARYA, A.; DEY, S. H. N. Multi-objective economic emission load dispatch solution using gravitational search algorithm and considering wind power penetration. **International Journal of Electrical Power & Energy Systems**, [S. l.], v. 44, n. 1, 2013.

NIU, Q. *et al.* Economic emission dispatch considering renewable energy resources – a multi-objective cross entropy optimization approach. **Sustainability**, [S. l.], v. 13, n. 10, p. 5386, 2021.

PARETO, V. **Manual of Political Economy**. New York: A. M. Kelley, 1971.

PAROUHA, R. An innovative hybrid algorithm for solving combined economic and emission dispatch problems. **Soft Computing**, (2022).

QU, B. Y. *et al.* Economic emission dispatch problems with stochastic wind power using summation based multi-objective evolutionary algorithm. **Information Sciences**, [S. l.], v. 351, p. 48-66. 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0020025516300172>. Acesso em: 7 set. 2022.

ROCHA, J. M. N. **Optimização de despacho económico integrando previsão de variabilidade de produção hídrica, eólica e solar**. Dissertação realizada no âmbito do Mestrado Integrado em Engenharia Electrotécnica e de Computadores Major Energia, Faculdade de Engenharia da Universidade do Porto, 2010.

RYU, H. S.; KIM, M. K. Combined economic emission dispatch with environment-based demand response using WU-ABC algorithm. **Energies**, [S. l.], v. 13, n. 23, p. 6450, 2020.

SAADAT, H. **Modern power systems analysis**. EUA: MCB, MC Grall-Hill, 1999.

STEVENSON JR., W. D. **Elementos de Análise de Sistemas de Potência**. 2ª ed. São Paulo: McGraw-Hill, 1986.

SUN, J. *et al.* “Quantum-behaved particle swarm optimization with Gaussian distributed local attractor point”. **Applied Mathematics and Computation**, [S. l.], v. 218, n. 7, 2011.

SUZIE, F. E. Canto dos Bichos: A Inteligência dos Cães – Parte 4. **Canto dos bichos**, 2010. Disponível em: <https://cantodosbichos.blogspot.com/2010/09/inteligencia-dos-caes-parte-4.html>. Acesso em: 27 abr. 2024.

VIANNA NETO, J. X.; BERNERT, D. L. A.; COELHO, L. S. Otimização de despacho econômico de energia elétrica baseado em um algoritmo evolutivo com inspiração quântica e

- informação de diversidade. *In*: Congresso Brasileiro de Redes Neurais/Inteligência Computacional, 9., 2009, Ouro Preto. **Anais...** Sociedade brasileira de redes neurais, 2009. p. 1-9.
- VIJAY, R. K.; NANDA, S. J. A Quantum Grey Wolf Optimizer based declustering model for analysis of earthquake catalogs in an ergodic framework. **Journal of Computational Science**, [S. l.], v. 36, 2019.
- WOOD, A. J.; WOLLENBERG, B. F. **Power Generation, Operation and Control**. 2^a ed. London, UK: John Wiley & Sons, 1996.
- XIN-GANG, Z. *et al.* An improved quantum particle swarm optimization algorithm for environmental economic dispatch. **Expert Systems With Applications**, [S. l.], v. 152, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417420301950?via%3Dihub>. Acesso em: 7 set. 2022.
- XIONG, G.; SHUAI, M.; HU, X. “Combined heat and power economic emission dispatch using improved bare-bone multi-objective particle swarm optimization”. **Energy**, [S. l.], v. 244, Part B, 2022.
- YANG, X-S. Flower pollination algorithm for global optimization. *In*: **International conference on unconventional computing and natural computation**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 240-249.
- YAO, F. *et al.* Quantum-inspired particle swarm optimization for power system operations considering wind power uncertainty and carbon tax in Australia. **IEEE transactions on industrial informatics**, [S. l.], v. 8, n. 4, p. 880-888, 2012.
- ZAVALA, V. M.; TLACUAHUAC, A. F. “Stability of multiobjective predictive control: A utopia-tracking approach”. **Automatica**, [S. l.], v. 48, n. 10, 2012.
- ZHU, Y.; WANG, J.; QU, B. Multi-objective economic emission dispatch considering wind power using evolutionary algorithm based on decomposition. **International Journal of Electrical Power & Energy Systems**, [S. l.], v. 63, p. 434-445, 2014.