



**UNIVERSIDADE FEDERAL DO PARÁ - UFPA
INSTITUTO DE TECNOLOGIA – ITEC
CAMPUS UNIVERSITÁRIO DO GUAMÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE**

TESE DE DOUTORADO

**USO DE TÉCNICAS DE OTIMIZAÇÃO METAHEURÍSTICAS APLICADAS AO
DESPACHO ECONÔMICO E AMBIENTAL DE USINAS TERMOELÉTRICAS E
FOTOVOLTAICAS**

TD 01/2023

BELÉM-PARÁ-BRASIL

2023



**UNIVERSIDADE FEDERAL DO PARÁ - UFPA
INSTITUTO DE TECNOLOGIA – ITEC
CAMPUS UNIVERSITÁRIO DO GUAMÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE**

Eliton Smith dos Santos

Orientador: Prof. Dr. Marcus Vinícius Alves Nunes

**USO DE TÉCNICAS DE OTIMIZAÇÃO METAHEURÍSTICAS APLICADAS AO
DESPACHO ECONÔMICO E AMBIENTAL DE USINAS TERMOELÉTRICAS E
FOTOVOLTAICAS**

Tese de Doutorado submetida à coordenação do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) do Instituto de Tecnologia da Universidade Federal do Pará (UFPA) como parte dos requisitos finais para obtenção do grau de Doutor em Engenharia Elétrica na área de Sistemas de Potência.

TD 01/2023

BELÉM-PARÁ-BRASIL

2023

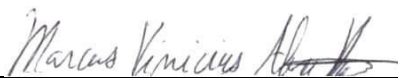
UNIVERSIDADE FEDERAL DO PARÁ - UFPA
INSTITUTO DE TECNOLOGIA – ITEC
CAMPUS UNIVERSITÁRIO DO GUAMÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE

USO DE TÉCNICAS DE OTIMIZAÇÃO METAHEURISTICAS APLICADAS AO
DESPACHO ECONÔMICO E AMBIENTAL DE USINAS TERMOELÉTRICAS E
FOTOVOLTAICAS

AUTOR: ELITON SMITH DOS SANTOS

TESE DE DOUTORADO SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ E JULGADA ADEQUADA PARA O DESENVOLVIMENTO DA TESE DE DOUTORADO EM ENGENHARIA ELÉTRICA NA ÁREA DE SISTEMAS DE ENERGIA.

APROVADA POR:



Prof. Dr. Marcus Vinicius Alves Nunes,
(Orientador – PPGE/UFPA)



(Ubiratan Holanda Bezerra – PPGE/UFPA)



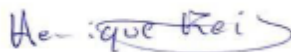
(Allan Arrifano Manito – FEEB/UFPA)



(Raphael Pablo de Sousa Barradas – MULTIFILAR Engenharia)



(Jandecy Cabral Leite – ITEGAM)



(Manoel Henrique Reis Nascimento – FUCAPI)

VISTO:



Prof. Dr. Diego Lisboa Cardoso
(Coordenador do PPGE/ITEC/UFPA)

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

S237u Santos, Eliton Smith dos.

Uso de técnicas de otimização metaheurísticas aplicadas ao despacho econômico e ambiental de usinas termoelétricas e fotovoltaicas. / Eliton Smith dos Santos. — 2023.

113 f. : il. color.

Orientador(a): Prof. Dr. Marcus Vinicius Alves Nunes
Tese (Doutorado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2023.

1. Despacho Econômico Ambiental. 2. Unidade Térmica.
3. Geração Solar Fotovoltaica. 4. Técnicas Metaheurísticas de Otimização. I. Título.

CDD 621.3191

Dedico esta conquista aos meus pais, esposa, filhos e irmãos pelo incentivo. Vocês foram fundamentais nesta caminhada.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, autor da vida, digno de toda honra e glória. A meus pais, Jose Alves dos Santos Junior (*IN MEMORIAM*) e Maria Jose Smith dos Santos, por sempre estarem presentes em minha vida, me apoiando e me incentivando a seguir sem medirem esforços para me oferecer uma boa educação com valores éticos e morais, ensinado a respeitar as outras pessoas. Em especial a minha esposa Normares, por ser minha companheira, amiga, minha inspiração e força, por ter me dado três lindos filhos, meus melhores presentes. A meus irmãos, por sempre estarem me apoiando.

A todos do ITEGAM em especial ao prof. Dr. Jandecy Leite, sua esposa Teresa e a Sra. Jacira que sempre me deram forças para prosseguir no doutorado. A meu amigo Cleonor Neves e sua mãe Elídia que tive o prazer de conhecer em Belém, onde me acolheu em sua casa e me tratou com um filho. Àqueles amigos que conheci no decorrer do curso, Airton, Anderson, Florindo, Renan Landau, Marcus Ciro, Douglas, Ruben Sicchar, Jorge Brito, Henrique Reis, Carlos Freitas, aos professores do ITEC-UFPA Carlos Tavares, Barra, Limão, professora Valquiria Gusmão, por ter me concedido sua sala na universidade para que eu pudesse realizar minhas pesquisas; em especial, ao meu orientador, Prof. Dr. Marcus Vinicius A. Nunes, pelos ensinamentos e orientações também por ter a paciência de me conduzir até a realização deste trabalho; Ao Prof. Dr. João Edgar (UFAM), que também me concedeu acesso livre a sua sala para prosseguir com minha pesquisa quando precisava ter acesso as revista de pesquisas; a meu meus amigos Jorge Penedo e Carlos Americo que me deram todo apoio para o termino do meu trabalho, a todos os outros que também contribuíram de forma direta e indireta para que concluísse minha pesquisa. Enfim, a UFPA, ITEGAM, FAPEAM e UNIP pelo suporte acadêmico e financeiro prestado durante o período de meu trabalho de pesquisa para o doutorado.

“Você ganha força, coragem e confiança através de cada experiência em que você realmente para e encara o medo de frente.”

Eleanor Roosevelt

RESUMO

O Despacho Econômico de Carga (ELD) é um processo do sistema elétrico de potência que visa o planejamento e a operação das Usinas Termelétricas (UTE), para o atendimento à demanda energética com menor custo operacional. Por outro lado, o ELD tornou-se um problema obsoleto por considerar somente o custo de combustível na geração de energia, desconsiderando parâmetros importantes como custos ambientais e de segurança da rede elétrica. A energia produzida pelas usinas termelétricas é considerada muito cara e poluente, ou seja, possui impactos negativos tanto na esfera ambiental, quanto para o cenário econômico. Considerando a pressão global para redução de emissões de poluentes na atmosfera e sustentabilidade ambiental, a incorporação da geração de Energias Renováveis (ER) ou Energias Verdes na rede elétrica é indispensável. A energia solar está se tornando uma parte importante do portfólio de geração de energia em muitas regiões devido à grande redução de seus custos e aos incentivos políticos que favorecem a geração de fontes de energia limpa e renováveis. Nesse sentido, a proposta da presente tese é apresentar um comparativo entre diversas técnicas metaheurísticas na otimização das soluções do Despacho Econômico Ambiental (DEA), incluindo a geração de energia solar fotovoltaica e o desligamento dos motores menos eficientes, bem como auxiliar o especialista na tomada de decisão para o funcionamento da planta geradora. Foram utilizados as metaheurísticas baseados em métodos estocásticos como: *Ant Lion Optimizer* (ALO), *Dragonfly Algorithm* (DA) e *Differential Evolution* (DE). Na busca por melhores soluções, foi implementado um novo algoritmo que verifica de forma inteligente a potência dos motores das usinas termelétricas. Com base na potência demandada para o horário, é utilizado até 70% da capacidade da geração da usina fotovoltaica sendo o restante da demanda atendido pela usina termelétrica. Assim, encontra-se a potência ideal para o número mínimo de motores suficientes para atender a demanda, reduzindo o nível de combustível e poluentes na atmosfera. As simulações foram geradas no ambiente computacional do MATLAB, utilizando um modelo híbrido composto por seis (06) Unidades Geradoras (UG) e treze (13) Usinas Solares Fotovoltaica (USF). Os resultados obtidos foram comparados com os das simulações de Khan, que utilizaram o Algoritmo de Otimização por Enxame de Partículas em inglês: *Particle Swarm Optimization* (PSO). São apresentadas ainda comparações entre os métodos utilizados, sendo que dentre as técnicas metaheurísticas testadas, o DE foi o método que apresentou os melhores resultados, garantindo uma redução no combustível fóssil em 3,02%, correspondendo a US\$ 8,557.08 e uma redução de poluentes na atmosfera de 1.42%.

Palavras-chave: Despacho Econômico Ambiental; Unidade Térmica; Geração Solar Fotovoltaica; Técnicas Metaheurísticas de Otimização.

ABSTRACT

Economic Load Dispatch (ELD) is a process of the electric power system that aims at the planning and operations of Thermoelectric Power Plants (TPP), to meet the demand with lower operating costs. Conversely, the ELD has become an obsolete problem that regard only the fuel cost in energy generation, disregarding important parameters, such as environmental costs and the safety of the electrical network. The energy produced by thermoelectric plants it's very expensive and polluting, that means, it has negative impacts on the environmental sphere and the economic scenario. Considering the global pressure to reduce pollutant emissions into the atmosphere and environmental sustainability, the incorporation of generation with Renewable Energies (RE) or Green Energies in the electric grid is indispensable. Solar energy is becoming an important part of the power generation portfolio in many regions due to the huge reduction in costs and the political incentives that favor the generation of clean and renewable energy sources. Seen in these terms, this thesis proposal is to submit a comparison between several metaheuristic techniques in the optimization of DEA solutions, including the generation of photovoltaic solar energy and the shutdown of less efficient engines, as well as helping the specialist in decision making for the operation from generator plant. Metaheuristics based on stochastic methods such as: Ant Lion Optimizer (ALO), Dragonfly Algorithm (DA) and Differential Evolution (DE) were used. In the search for better solutions, a new algorithm was implemented that intelligently checks the power of the thermoelectric motors. Based on the power demanded for time, up to 70% of the generation capacity of the photovoltaic plant is used and the rest is supplied by the thermoelectric plant. Thereby, the ideal power is found for the minimum number of engines sufficient to meet the demand, reducing the level of fuel and pollutants in the atmosphere. The simulations were generated in the MATLAB environment, using a hybrid model composed of six (06) Generating Units (GU) and thirteen (13) Solar Photovoltaic Plants (SPP). As a result, they were compared with the results of Khan's simulations, which used PSO (Particle Swarm Optimization). For that matter, the thesis presents comparative results of the methods used, among the techniques used, the DE was the method that presented the best results, guaranteeing a reduction in fossil fuel by 3.02%, corresponding to US\$ 8,557.08 and a reduction of pollutants in the atmosphere of 1.42%.

Keywords: Environmental Economic Dispatch; Thermal Unit; Photovoltaic Solar Generation; Metaheuristic Optimization Techniques.

LISTA DE FIGURAS

Figura 1 - Exemplo de uma curva de Pareto.	26
Figura 2 - Banda de valência, gap (GAP) e banda de condução: isolador, condutor e semicondutor.	42
Figura 3 - Diagrama de sistema fotovoltaico autônomo ou isolado em função da carga utilizada.	44
Figura 4 - Modelo de Configuração.	45
Figura 5 - Diagrama de um sistema fotovoltaico conectado à rede.	47
Figura 6 - Diagrama de um sistema Híbrido.	48
Figura 7 - Consumo de combustível sem efeito de ponto de válvula.	53
Figura 8 - Curva de custo incremental.	56
Figura 9 - Armadilhas em forma de cone e comportamento de caça da formiga leão.	58
Figura 10 - Armadilhas em forma de cone e comportamento de caça da formiga leão.	59
Figura 11 - Comportamento Natural das Libélulas	65
Figura 12 - Fluxograma do ALO para problema do despacho econômica ambiental.	71
Figura 13 - O pseudocódigo do algoritmo DA, adaptado de (MIRJALILI, 2016).	72
Figura 14 - Fluxograma do DA para problema do despacho econômica ambiental.	73
Figura 15 - Fluxograma do DE para problema do despacho econômica ambiental.	74
Figura 16 – Diagrama Unifilar do Sistema de Teste com 6 UG e 13 USF.	78
Figura 17 - Comparação entre Potência e Emissões por Geradores.	80
Figura 18 - Custo de Combustível por Geradores.	80
Figura 19 - Comparação entre Potência e Emissões por Geradores.	81
Figura 20 - Custo de Combustível por Geradores.	81
Figura 21 - Comparação entre Potência e Emissões por Geradores.	81
Figura 22 - Custo de Combustível por Geradores.	81
Figura 23 - Frente de Pareto técnica DE simulado às 10:00h	81
Figura 24 - Comparação entre Potência e Emissões por Geradores.	83
Figura 25 - Custo de Combustível por Geradores	83
Figura 26 - Comparação entre Potência e Emissões por Geradores.	84
Figura 27 - Custo de Combustível por Geradores	84
Figura 28 - Comparação entre Potência e Emissões por Geradores.	84

Figura 29 - Custo de Combustível por Geradores	84
Figura 30 - Frente de Pareto técnica DE simulado às 11:00h.	84
Figura 31 - Comparação entre Potência e Emissões por Geradores.....	86
Figura 32 - Custo de Combustível por Geradores	86
Figura 33 - Comparação entre Potência e Emissões por Geradores.....	87
Figura 34 - Custo de Combustível por Geradores.....	87
Figura 35 - Comparação entre Potência e Emissões por Geradores.....	87
Figura 36 - Custo de Combustível por Geradores.	87
Figura 37 - Frente de Pareto técnica DE simulado às 12:00h.	87
Figura 38 - Comparação entre Potência e Emissões por Geradores.....	89
Figura 39 - Custo de Combustível por Geradores.....	89
Figura 40 - Comparação entre Potência e Emissões por Geradores.....	90
Figura 41 - Custo de Combustível por Geradores.....	90
Figura 42 - Comparação entre Potência e Emissões por Geradores.....	90
Figura 43 - Custo de Combustível por Geradores.....	90
Figura 44 - Frente de Pareto técnica DE simulado às 13:00.	90
Figura 45 - Comparação entre Potência e Emissões por Geradores.....	92
Figura 46 - Custo de Combustível por Geradores.....	92
Figura 47 - Comparação entre Potência e Emissões por Geradores.....	93
Figura 48 - Custo de Combustível por Geradores.....	93
Figura 49 - Comparação entre Potência e Emissões por Geradores.....	93
Figura 50 - Custo de Combustível por Geradores.....	93
Figura 51 - Frente de Pareto técnica DE simulado às 14:00h.	93
Figura 52 - Comparação entre Potência e Emissões por Geradores.....	95
Figura 53 - Custo de Combustível por Geradores.....	95
Figura 54 - Comparação entre Potência e Emissões por Geradores.....	96
Figura 55 - Custo de Combustível por Geradores.....	96
Figura 56 - Comparação entre Potência e Emissões por Geradores.....	96
Figura 57 - Custo de Combustível por Geradores.....	96
Figura 58 - Frente de Pareto técnica DE simulado às 15:00h.	96
Figura 59 - Total geral do custo de combustível simulado entre as técnicas de otimização. ..	98
Figura 60 – Redução das Emissões entre as técnicas de otimização utilizadas.	99

LISTA DE TABELAS

Tabela 1 - Padrões de qualidade do ar no Brasil.	36
Tabela 2 - Dados para determinar o índice de emissão dos motores a gás.....	37
Tabela 3 - Fatores de conversão.	37
Tabela 4 - Pesos moleculares.....	38
Tabela 5 - Emissões Típicas dos motores a gás.....	38
Tabela 6 - Dados para determinar o índice de emissão dos motores a HFO.....	39
Tabela 7 - Fatores de conversão no caso dos motores a HFO.....	39
Tabela 8 - Emissões típicas de um motor MAN a HFO.....	40
Tabela 9 - Coeficientes de custo de combustível para cada unidade geradora UTE.....	75
Tabela 10 - Coeficientes de emissão das usinas.	75
Tabela 11 - Classificações de energia e taxas por unidade de USF.....	76
Tabela 12 - Radiação solar, demanda de energia e temperatura.....	77
Tabela 13 - Resultados obtidos com as técnicas incluindo energia solar para demanda de 1244 MW às 10:00h.	79
Tabela 14 - Resultados obtidos com as técnicas incluindo energia solar para demanda de 1088 MW às 11: 00h.	82
Tabela 15 - Resultados da comparação com a energia solar para demanda de 1240 MW às 12h00.	85
Tabela 16 - Resultados da comparação com a energia solar para demanda de 1135 MW às 13:00h.	88
Tabela 17 - Resultados da comparação com a energia solar para demanda de 1318 MW às 14:00h.	91
Tabela 18 - Resultados da comparação com a energia solar para demanda de 1074 MW às 15h00.	94
Tabela 19 - Comparação do custo total de combustível entre as técnicas.....	97
Tabela 20 – Redução das emissões entre as técnicas de otimização.	98

LISTA DA SIGLAS

ALO	<i>Ant Lion Optimizer</i>
AS	<i>Simulated Annealing</i>
DA	<i>Dragonfly Algorithm</i>
DE	<i>Differential Evolution</i>
DEA	Despacho Econômico Ambiental
ELD	Despacho Econômico de Carga
ER	Energia Renovável
ETS	<i>Emission Trading Scheme</i>
MOPSO	Otimização Multiobjetivo por Enxame de Partículas
MQAP	<i>Multiobjective Quadratic Attribution Problem</i>
ONU	Organização das Nações Unidas
PSO	<i>Particle Swarm Optimization</i>
SFCR	Sistema Fotovoltaico Conectado à Rede
UG	Unidades Geradoras
USF	Usina Solar Fotovoltaica
UTE	Usinas Termelétricas

LISTA DE SIMBOLOS

SO_2	Dióxido de Enxofre
CO_2	Dióxido de Carbono
CO	Monóxido de Carbono
NO_x	Óxido de Nitrogênio
O_3	Ozônio
F_1	Potência da usina solar
P_{gsj}	Potência do gerador solar
P_{rated}	Potência Nominal
T_{ref}	Temperatura de Referência
T_{amb}	Temperatura Ambiente
α	Coefficiente de Temperatura
S_i	Radiação Solar Incidente
F_2	Função de Custo de Combustível
F_3	Função de Custo Ambiental
IC_i	Custo de combustível incremental
a_i	Curva de custo incremental real
b_i	Curva de custo incremental aproximada (linear)
P_{gi}	Geração total de energia.
P_i	Potência nominal de cada unidade geradora
P^D	Demanda de potência
P^L	Perdas na transmissão
$\alpha_i, \beta_i, \gamma_i$	Representam os coeficientes de emissão de cada unidade geradora.

SUMARIO

RESUMO.....	8
ABSTRACT	9
LISTA DE FIGURAS	10
LISTA DE TABELAS	12
LISTA DA SIGLAS.....	13
LISTA DE SIMBOLOS	14
SUMARIO	15
CAPÍTULO I.....	18
1 INTRODUÇÃO	18
1.1 IDENTIFICAÇÃO E JUSTIFICATIVA DA PROPOSTA	20
1.2 PROBLEMA DA PESQUISA.....	21
1.3 OBJETIVOS	21
1.3.1 <i>Objetivo Geral</i>	21
1.3.2 <i>Objetivos Específicos</i>	21
1.4 CONTRIBUIÇÃO E RELEVÂNCIA DO TEMA	22
1.5 DELIMITAÇÕES DA PESQUISA	22
1.6 ESTRUTURA DA TESE.....	23
CAPÍTULO II.....	24
2 ESTADO DA ARTE.....	24
2.1 TÉCNICAS DE OTIMIZAÇÃO	24
2.1.1 <i>Otimização de Multiobjetivos e soluções ótimas da Frente de Pareto</i>	24
2.1.2 <i>Técnicas de Resolução de Problemas de Otimização Multiobjetivo</i>	26
2.1.3 <i>Outros Trabalhos em Problemas de Otimização Combinatória Multiobjetivo</i>	27
2.1.4 <i>Otimização Combinatória Multiobjetivo Utilizando Metaheurísticas</i>	28
2.2 DESPACHO ECONÔMICO AMBIENTAL.....	31
2.2.1 <i>O índice de Emissões como Parâmetro para Avaliar a Contaminação Ambiental de Usinas Térmicas</i>	31
2.2.2 <i>Resolução do CONAMA</i>	35
2.2.3 <i>Índice de Emissões dos Motores a Gás</i>	36
2.2.4 <i>Índice de Emissões dos Motores a HFO</i>	39
2.3 ENERGIAS RENOVÁVEIS	40

2.3.1	<i>Energia Solar Fotovoltaica</i>	41
2.3.1.1	Sistemas Fotovoltaicos Autônomos ou Isolados	43
2.3.1.2	Sistema fotovoltaico conectado à rede	45
2.3.1.3	Sistemas Híbridos.....	47
2.4	USINAS TERMOELÉTRICAS	49
2.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO II.....	49
CAPÍTULO III.....		51
3 MODELO MATEMÁTICO PARA APLICAÇÃO DA METODOLOGIA		51
3.1	MODELO MATEMÁTICO DE GERAÇÃO POR USINA SOLAR (F1).....	51
3.2	MODELO MATEMÁTICO DE CUSTO DE TERMELÉTRICAS (F2)	52
3.3	MODELO MATEMÁTICO DAS EMISSÕES EM USINAS TÉRMICAS (F3).....	53
3.4	RESTRIÇÕES DE DESPACHO ECONÔMICO DE CARGA.....	54
3.4.1	<i>Restrição de Equilíbrio de Potência</i>	54
3.4.2	<i>Restrição de Geração</i>	55
3.5	PROBLEMA DE OTIMIZAÇÃO	55
3.6	FORMULAÇÃO DO CUSTO INCREMENTAL	56
3.7	CONSIDERAÇÕES FINAIS DO CAPÍTULO III.....	57
CAPÍTULO IV.....		58
4 TÉCNICAS METAHEURÍSTICAS.....		58
4.1	ALGORITMO DE OTIMIZAÇÃO ANT LION OPTIMIZER	58
4.2	ALGORITMO DE OTIMIZAÇÃO DRAGONFLY ALGORITHM	61
4.3	ALGORITMO DIFFERENTIAL EVOLUTION.....	66
4.3.1	<i>Operação de Inicialização</i>	66
4.3.2	<i>Operação de Mutação</i>	67
4.3.3	<i>Operação de Cruzamento</i>	67
4.3.4	<i>Operação de Seleção</i>	68
4.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO IV	68
CAPÍTULO V.....		69
5 PROPOSTA DA TESE E METODOLOGIA		69
5.1	RESOLVENDO O PROBLEMA DEA COM ANT LION OPTIMIZER (ALO).....	69
5.2	RESOLVENDO O PROBLEMA DEA COM DRAGONFLY ALGORITHM (DA).....	71
5.3	RESOLVENDO O PROBLEMA DEA COM DIFFERENTIAL EVOLUTION (DE).....	73
5.4	ESTUDO DE CASO: SISTEMA DE TESTE DE 6 UNIDADES IEEE E 13 USINAS SOLARES	75
5.5	ANÁLISE E DISCUSSÃO DOS RESULTADOS	78
5.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO V	100

CAPÍTULO VI.....	101
6 CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS	101
6.1 PROPOSTAS PARA TRABALHOS FUTUROS	102
REFERÊNCIAS BIBLIOGRÁFICAS	103

CAPÍTULO I

1 INTRODUÇÃO

Devido à atual crise energética e ao aumento excessivo do consumo de energia, problemas econômicos e ambientais na geração de energia forçam as concessionárias e os produtores de energia a considerar o impacto ambiental das termelétricas. Medidas para reduzir a crise energética no Brasil, tem demandado do poder público ações para conter os gastos inúteis de energia e procurar possibilidades de uso de outras fontes energéticas, contudo essas medidas ainda são tímidas. Uma das soluções para redução dessa crise, está relacionada com o acionamento das termelétricas para compensar a energia antes produzidas pelas hidrelétricas. Por outro lado, a energia produzida pelas termelétricas é considerada muito cara e poluente, ou seja, possui impactos negativos para a esfera ambiental e o cenário econômico.

No contexto atual, as questões climáticas, o aquecimento global e a crise energética estão se tornando cada vez mais graves e têm recebido muita atenção dos pesquisadores. A melhoria na eficiência da utilização de energia e a redução da emissão de gases de efeito estufa, tem se tornado uma questão cada vez mais necessária para toda a indústria de energia. As principais causas do aquecimento global são as emissões causadas pelos problemas do Despacho Econômico de Carga que emitem poluentes como: dióxido de enxofre (SO₂), dióxido de carbono (CO₂), monóxido de carbono (CO) e óxido de nitrogênio (NO_x). Embora algumas soluções sejam propostas para reduzir as emissões e os custos de produção, considerando tanto o custo quanto a emissão de forma otimizada, levando a um DEA, as soluções requerem algoritmos de otimização eficientes (DAS; BHATTACHARYA; RAY, 2020; SHETA et al., 2020).

Desse modo, para reduzir o aquecimento global e diminuir a dependência de combustíveis fósseis, o investimento em fontes de energias limpas e renováveis é uma das principais ações recomendadas pela Organização das Nações Unidas (ONU) para o desenvolvimento sustentável. A ONU afirma que as fontes de energias renováveis, dentre elas, a energia solar, é um dos meios para o mundo não ultrapassar o cenário limite de variação na temperatura. Pois, ainda que nenhuma fonte de energia, mesmo que renovável, esteja inteiramente livre de impactos ambientais, a energia solar apresenta um dos menores impactos entre as demais. Assim, unidades convencionais podem ser integradas, trazendo benefícios consideráveis ao mercado de energia (DEB et al., 2021; HASSELEIN, 2021).

Os problemas do ELD são problemas de otimização não lineares. No entanto, muitos métodos clássicos de otimização heurísticos do ELD foram implementados para reduzir apenas um objetivo, ou seja, o custo de combustível. Portanto, para reduzir o impacto ambiental e a geração ótima, foi implementado uma otimização de múltiplos objetivos, tornando-se, o Despacho Econômico Ambiental (DEA) (AFANDI; MIYAUCHI, 2014; HADJI et al., 2015; KHAN et al., 2015c). Um novo conceito de fator de penalidade de preço é proposto por alguns pesquisadores para resolver o problema do DEA (MA et al., 2017; MOHAMMED; MURPHY; NDOYE, 2021; REFAI; EBEED; KAMEL, 2019).

A solução do DEA minimiza o custo geral de produção e emissões suprindo a demanda de carga. A função de custo de combustível é considerada na forma quadrática (GOYAL et al., 2020). Muitas técnicas foram introduzidas e propostas para resolver o problema do Despacho Econômico de Carga do sistema de potência (AFANDI, 2016; ZHENG et al., 2018). Por exemplo: Em (SADOUDI; BOUDOUR; KOUBA, 2018), um problema de (DE) não convexo foi abordado por várias técnicas de otimização híbrida. Em (MOHAMMED; MURPHY; NDOYE, 2021), uma técnica baseada em (PSO) com fator de constrição (CFPSO) foi proposta para (DE) com efeitos de ponto valvar; A técnica (CFPSO) mostrou ser de rápida convergência. Em (MOHAMMED; MURPHY; NDOYE, 2021), eles resolveram o problema do DEA sob as restrições de balanço de energia e limites de capacidade de geração de energia usando PSO. Em (MALIK et al., 2020), a otimização multiobjetivo por enxame de partículas (MOPSO) foi proposta, e eles usaram um mecanismo de preservação da diversidade para encontrar a ampla gama de soluções ótimas de pareto.

O modelo proposto consiste em distribuir a demanda de geração de energia, entre fontes renováveis e não renováveis (sistema híbrido), nas usinas de forma econômica, reduzindo custos com combustíveis e emissões de gases poluentes e mantendo a estabilidade da rede elétrica após a inserção da energia solar fotovoltaica. A estrutura do modelo proposto é composta por 6 (seis) Unidades Geradoras (UG's) e 13 (treze) USF, para otimizar o problema de DEA, além do uso racional dos geradores mais eficientes permitindo a manutenção preditiva das UG. Foram utilizados algoritmos metaheurísticos baseados em processos estocástica como: Ant Lion Optimizer (ALO), Dragonfly Algorithm (DA) e Differential Evolution (DE). Na busca por melhores soluções, foi implementado um novo algoritmo que define de forma inteligente os geradores e suas respectivas potências nominais. Com base na potência demandada, são identificados os geradores de menor eficiência e com o auxílio da produção de energia solar fotovoltaica consegue desligá-los, dependendo da demanda solicitada para o horário, reduzindo

o consumo de combustível e os níveis de poluentes na atmosfera. Os resultados das simulações foram computados no ambiente do MATLAB, utilizando os dados de demanda de energia obtidos da Islamabad Electric Supply Company (IESCO) (KHAN et al., 2015c).

1.1 Identificação e Justificativa da Proposta

Com as constantes pesquisas relacionadas à eficiência energética e o despacho de carga, surge a necessidade de estudos desenvolvidos com o intuito de conseguir otimizar o despacho tornando-o mais econômico e menos contaminante por parte dos motores das usinas térmicas.

O uso de energia solar fotovoltaica é promissor, especialmente para países com abundância de recursos solares, de modo a garantir seu abastecimento de energia, reduzir a emissão de carbono e, conseqüentemente, alcançar objetivos de desenvolvimento sustentável. Além disso, a geração de energia nas UTE's é oriunda da queima de combustíveis fósseis, como o carvão, o óleo diesel, a gasolina, o gás natural, entre outros derivados do petróleo. No Brasil, a energia termoelétrica é a segunda forma mais usada para geração de energia. Devido seu grande potencial fluvial, o país utiliza as usinas hidrelétricas para a maior parte da produção energética.

Combinando a geração de energia termoelétrica com usinas solares fotovoltaicas é oferecida a oportunidade de tornar essas usinas economicamente competitivas e confiáveis durante sua operação, equilibrando a oferta e demanda de energia, reduzindo os impactos indesejáveis ao meio ambiente e reduzindo o custo na compra de combustíveis derivados do petróleo.

O acréscimo das cobranças referentes à minimização dos impactos ambientais estabelece que as emissões de gases tenham que ser compreendidas e controladas no problema do DE. As emissões de poluentes ameaçadores e nocivos, como SO_2 , NO_x , CO e CO_2 deram origem a muitos trabalhos científicos que buscam e desenvolvem formas de reduzir a emissão desses poluentes (MA; HOVY, 2016; ROY; BHUI, 2016; TURGUT; DEMIR, 2017).

Nesse sentido, a proposta da tese é apresentar soluções para garantir a redução dos custos de combustíveis e poluentes na atmosfera em um sistema de energia híbrido, tornando um problema multiobjetivo de Despacho Econômico Ambiental e ajudar na tomada de decisão para garantir a produção de energia mais eficiente. Foram utilizados algoritmos metaheurísticos baseados em métodos estocástica como: Formiga Leão do inglês *Ant Lion Optimizer* (ALO), Algoritmo da Libelula do inglês *Dragonfly Algorithm* (DA) e Evolução diferencial *Differential Evolution Algorithm* (DE). Na busca por melhores soluções, foi implementado um novo

algoritmo que verifica de forma inteligente a potência entre os geradores da termoeletrica. Com base na potência demandada, são identificados os geradores de menor potência e com o auxílio da produção de energia solar fotovoltaica consegue desligá-los ou não, dependendo da demanda solicitada para o horário. Assim, encontra-se a potência ideal para os demais geradores reduzindo o nível de combustível e poluentes na atmosfera.

1.2 Problema da Pesquisa

Considerando a pressão global para redução das emissões de poluentes na atmosfera e a sustentabilidade ambiental, bem como a escassez de recursos hídricos e o aumento significativo do uso de energia elétrica global, tendo em vista o aumento significativo da população, o problema considerado é atender a demanda de energia elétrica, reduzindo a geração de energia termelétrica com a utilização de energia renovável (energia solar) e consequentemente, otimizar o problema do DEA.

1.3 Objetivos

1.3.1 Objetivo Geral

Implementar uma solução para otimização do DEA em um sistema híbrido com energia fotovoltaica comparando com outras técnicas metaheurísticas.

1.3.2 Objetivos Específicos

- Modelar o problema de otimização do DEA, buscando encontrar melhores resultados, entre as técnicas metaheurísticas ALO, DA e DE;
- Simular no ambiente do MATLAB os algoritmos de otimização propostos para o DEA;
- Analisar o consumo de combustível na produção de energia das UTE com o uso da energia solar fotovoltaica e o desligamento inteligente dos geradores com menor potência;
- Avaliar os resultados obtidos nas simulações das técnicas metaheurísticas para minimizar o problema do DEA.

1.4 Contribuição e Relevância do Tema

A presente proposta pretende aperfeiçoar os métodos que verificam de forma inteligente a potência dos geradores da termoelétrica em sistemas híbridos de geração de energia através do Despacho Econômico Ambiental.

Existem diversas citações na literatura para resolver o problema do DEA, entretanto todos esses métodos quando praticados não contemplam os benefícios da implementação de um novo algoritmo que busca de forma inteligente a melhoria da potência dos geradores da termoelétrica. Com base na potência demandada, são identificados os geradores de menor potência e com o auxílio da produção de energia solar fotovoltaica consegue desligá-los ou não, dependendo da demanda solicitada para o horário. Assim, encontra-se a potência ideal para os demais geradores reduzindo o nível de combustível e poluentes na atmosfera.

Esse trabalho propõem uma nova solução para o problema do DEA utilizando procedimentos computacionais metaheurísticos: *Ant Lion Optimizer* (ALO), *Dragonfly Algorithm* (DA) e *Differential Evolution* (DE). E para a simulação foram obedecidas às restrições de funcionamento das plantas UTE e SPP, bem como, os coeficientes das curvas de custo e de emissões, que oferecem as seguintes novidades e/ou contribuições:

1. Uma solução para o problema de otimização do DEA, que garante a redução dos indicadores de desperdício, consumo, emissões de gases poluentes em consonância com as restrições apropriadas para o problema segundo as normas ambientais e sustentáveis;
2. Melhores resultados do custo de geração, utilizando as técnicas metaheurísticas ALO, DA e DE quando comparada com os resultados obtidos pela técnica do PSO;
3. Implementação computacional da nova solução para um sistema híbrido.
4. Utilização de técnicas que minimizem a convergência para ótimos locais, alcançando ótimos globais.

Desta forma, todas as simulações foram desenvolvidas no ambiente computacional do MATLAB que será mostrado nos capítulos seguintes.

1.5 Delimitações da Pesquisa

Essa pesquisa propõe realizar a comparação das técnicas metaheurísticas *Ant Lion Optimizer* (ALO), *DragonFly Algorithm* (DA) e *Differential Evolution* (DE) para otimização do DEA utilizando um sistema de geração híbrido composto por seis (06) UG's e treze (13) USF.

1.6 Estrutura da Tese

Esta tese está dividida em seis capítulos. No primeiro Capítulo, descrevemos a contextualização do trabalho, a inovação científica, sua contribuição e relevância, seus objetivos, o que compreende o problema da pesquisa e sua delimitação.

No segundo Capítulo, apresentamos a explanação do estado da arte, sobre uma revisão da literatura, com relação as técnicas de otimização do Despacho Econômico Ambiental e Energias Renováveis.

No terceiro Capítulo é descrito o modelo matemático das funções objetivo, das equações de restrições e as modelagens dos sistemas.

No quarto Capítulo é abordado sobre as técnicas metaheurísticas ALO, DA e DE.

No quinto Capítulo são descritos e analisados os resultados do estudo de caso, aplicando o modelo proposto a uma UTE de 6 UG do IEEE com a inclusão de 13 usinas solares fotovoltaica.

O sexto Capítulo são apresentadas as conclusões resultantes da tese e as recomendações para trabalhos futuros.

CAPÍTULO II

2 ESTADO DA ARTE

Neste capítulo serão apresentados os conceitos básicos e definições relacionadas as Técnicas de Otimização, Despacho Econômico de Carga, Despacho Ambiental e sobre Energia Renováveis com uma abordagem focada em Energia Solar Fotovoltaica.

2.1 Técnicas de Otimização

Nesta seção é introduzido o conceito de otimização multiobjetivo, para explorar as técnicas mais empregadas nas diversas categorias de problemas atuais e a forma de modelar a solução multicritério para obter um grupo de soluções que auxiliem o tomador de decisão a adequar as respostas encontradas a seu problema de maneira a maximizar a sua eficiência.

Alguns engenheiros, analistas e gerentes muitas vezes enfrentam o desafio de fazer compensações entre diferentes fatores para alcançar os resultados desejáveis. Otimização é o processo de escolher essas compensações da "melhor" maneira. A noção de 'fatores diferentes' significa que existem diferentes soluções possíveis. Portanto, em um problema de otimização, diferentes soluções candidatas são comparadas e contrastadas, o que significa que a qualidade da solução é fundamental (FILIPPI; GUASTARROBA; SPERANZA, 2016; STRUB; BAUMANN, 2018).

2.1.1 Otimização de Multiobjetivos e soluções ótimas da Frente de Pareto

Como apresentado por (CARAMIA; DELL'OLMO, 2021) um problema de otimização de objetivo único pode ser formulado conforme Eq.(2.1):

$$\begin{aligned} \min f(x) \\ x \in S \end{aligned} \tag{2.1}$$

onde f é uma função escalar e S é um grupo de restrições que podem ser definidas como $S = \{x \in R^m: h(x) = 0, g(x) \geq 0\}$.

A otimização multiobjetivo pode então ser escrita em termos matemáticos descritos em Eq. (2.2)

$$\min[f_1(x), f_2(x), \dots, f_n(x)] \tag{2.2}$$

$$x \in S,$$

onde $n > 1$ e S é o grupo de restrições refere-se aos previamente definidos. O espaço denominado como "espaço de objetivos" contém o vetor com os vários objetivos e o espaço alcançado contém a imagem de todo grupo considerado apto pela função de aptidão f . Tal espaço é definido em Eq. (2.3).

$$C = \{y \in R^n: y = f(x), x \in S\}. \quad (2.3)$$

O conceito escalar de "ótimo" não se aplica diretamente a um grupo de otimização multiobjetivo. Ao invés de um número escalar indicando o "ótimo" a solução multiobjetivo introduz um conceito de "Pareto ótimo". O conceito consiste no fato que todo o vetor $x^* \in S$ é considerado contido no Pareto ótimo de um problema multiobjetivo se e somente se todos os vetores $x \in S$ tenham um valor maior de pelo menos uma das funções objetivo f_i , sendo $i = 1, 2, \dots, n$, ou tenha o mesmo valor de algumas funções objetivo. Levando este argumento em consideração as definições de "Pareto ótimo fraco" e "Pareto ótimo restrito" são definidas a seguir:

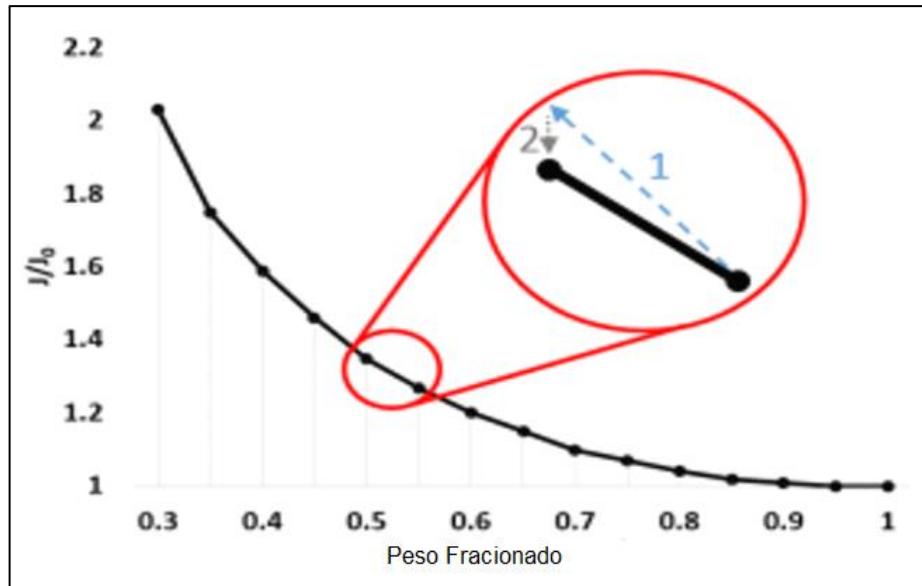
- Pareto ótimo fraco ou solução eficiente fraca de multiobjetivo é toda solução x^* tal que não exista um elemento $x \in S$ que satisfaça $f_i(x) < f_i(x^*)$ para todo $i \in \{1, \dots, n\}$.
- Pareto ótimo restrito ou solução eficiente restrita de um problema multiobjetivo é toda solução x^* tal que não exista um elemento $x \in S$ que satisfaça $f_i(x) \leq f_i(x^*)$ para todo $i \in \{1, \dots, n\}$, com pelo menos uma desigualdade restrita.

De posse das definições sobre as regiões do gráfico de Pareto, os pontos locais de Pareto ótimo podem ser definidos também de acordo com a vizinhança de aptidão do ponto x^* . Em outros termos, considere que se $B(x^*, \varepsilon)$ for um círculo ou uma esfera de raio $\varepsilon > 0$ em torno do ponto x^* , é necessário que para algum ponto de $\varepsilon > 0$, não exista um $x \in S \cap B(x^*, \varepsilon)$ tal que $f_i(x) \leq f_i(x^*)$ para todo $i \in \{1, \dots, n\}$, com pelo menos uma desigualdade restrita.

A que contém todas as soluções eficientes é conhecida como frente de Pareto, curva de Pareto ou superfície de Pareto. A forma da figura de Pareto indica a natureza das trocas entre as funções objetivo. A Figura 1, mostra um exemplo de curva de Pareto, onde todos os pontos

$(f_2(\hat{x}), f_1(\hat{x}))$ e $(f_2(\tilde{x}), f_1(\tilde{x}))$ definem a frente de Pareto. Estes pontos são conhecidos como pontos não dominados ou não inferiores.

Figura 1 - Exemplo de uma curva de Pareto.



Fonte: (MIRZENDEHDEL; SURESH, 2015).

2.1.2 Técnicas de Resolução de Problemas de Otimização Multiobjetivo

Em muitos casos, as curvas de Pareto não podem ser computadas de maneira eficiente. Embora na teoria seja possível encontrar exatamente todos os pontos, é possível que eles apresentem um tamanho exponencial. Exemplo: uma redução na íntegra do problema da mochila demonstra que ele é do tipo *NP-hard* para computar. Para estas condições existem métodos de aproximação que são frequentemente utilizados nos mesmos. No entanto, muitas vezes a aproximação não representa uma escolha secundária para o tomador de decisão (CARAMIA, 2020). De fato, existem muitos problemas da realidade dos quais são muito difíceis para o tomador de decisão colher todas as informações para formular estes problemas de maneira correta. Considerando que os tomadores de decisão tendem a entender mais sobre o problema assim que algumas soluções preliminares são apresentadas ter algumas soluções aproximadas podem ajudar o tomador de decisão em sua tarefa conforme apresentado por (DELL'OLMO, 2020).

Técnicas de aproximação geralmente apresentam objetivos variados tais como: representação de um grupo de soluções gráficas que podem ser convertidos para números (problemas multiobjetivo convexos); representação de um grupo de soluções gráficas onde

apenas algumas curvas de Pareto podem ser representadas numericamente (problemas multiobjetivo não-lineares); representação de um grupo de soluções gráficas onde todo grupo eficiente de soluções não pode ser representado numericamente (problemas multiobjetivo discretos) (MORADI, 2020; QIN et al., 2019; RAO; RAI; BALIC, 2017).

De fato, a otimização multiobjetivo ou "multicritério" tem sido alvo de várias pesquisas. (RAUNIYAR; NATH; MUHURI, 2019; ZEYNALI; ROSTAMI; FEYZI, 2020)

Para (ANTUNES; HENRIQUES, 2016) relatam um estudo reunindo as mais variadas técnicas de otimização. No trabalho de (PILKO; MANDŽUKA; BARIĆ, 2017) as diversas técnicas são aplicadas a duas funções objetivo separadamente e um caso em que o número de funções objetivo é estritamente maior que dois. No livro de (EHRGOTT; WIECEK, 2005) e no seu artigo de (WIECEK; EHRGOTT; ENGAU, 2016) diversas técnicas de transformação escalar são abordadas. Em (T'KINDT; BILLAUT, 2006), dedicam um capítulo do seu livro para "programação multicritério" onde aborda vários métodos de otimização multiobjetivos.

2.1.3 Outros Trabalhos em Problemas de Otimização Combinatória Multiobjetivo

No artigo intitulado "Um método de ajuste de nível para otimização combinatória multiobjetivo: aplicada ao problema de designação quadrática", (QIN et al., 2019) estudaram o problema de designação em um caso multiobjetivo.

A versão básica do bastante conhecido problema de atribuição (assignment problem - AP) pode ser definido em um gráfico de duas partes. Uma maneira interessante de tratar um problema de atribuição seria o de encontrar o número de arestas que não possuem vértices em comum, por exemplo, para modelar o problema considera-se a atribuição de cargas para caminhões ou pessoas (motoristas) para veículos então um modo de maximizar a atribuição de cargas seria o mesmo que tentar encontrar o número máximo de cargas atribuídas para os caminhões (onde as arestas entre uma carga e um caminhão significam um grau de compatibilidade). Em outros casos as arestas podem ser legendadas, por exemplo, com uma estimativa do pagamento obtido através de certa atribuição, então o objetivo seria pesquisar pelo grupo de arestas sem vértices em comum que maximize o pagamento total estimado.

De modo similar, se as legendas das arestas representarem um custo, o objetivo torna-se o de encontrar a atribuição que minimize o custo total. (MAGNANTI; ORLIN, 1993) apresentam em seu livro intitulado "Network Flows: Theory, Algorithms, and Applications" uma série de algoritmos e variações dos problemas de atribuição e de fluxo de rede.

No estudo da versão de atribuição quadrática do problema com múltiplos objetivos, (SUN et al., 2020) propôs uma meta dupla: a primeira delas propõe o desenvolvimento de um procedimento para a determinação das soluções ótimas de Pareto em problemas de otimização combinatorial multiobjetivo e a segunda meta demonstra a eficácia do método. O método proposto para alcançar a primeira meta tem como base o resultado da pesquisa realizada por (ZEYNALI; ROSTAMI; FEYZI, 2020). A rotina, baseada na noção de níveis de grupos e níveis de curvas, trabalha com um número arbitrário de objetivos, cujo propósito utilizava um algoritmo que resolvesse o problema de encontrar a melhor solução K em um problema de otimização combinatoria multiobjetivo. Com relação à segunda meta de resolver o problema de atribuição quadrática multiobjetivo (*Multiobjective Quadratic Attribution Problem - MQAP*), o método apresentado demonstrou bastante eficiência e através da literatura tornou-se o primeiro método capaz de lidar com esta categoria de problema combinatoria. Ainda na mesma pesquisa de 2006 foram apresentados dois algoritmos que classificavam as soluções do (*Quadratic Attribution Problem - QAP*) e reportaram as experiências comparativas realizadas utilizando vários exemplos aleatórios cujos objetivos variavam entre dois e seis.

2.1.4 Otimização Combinatória Multiobjetivo Utilizando Metaheurísticas

O primeiro trabalho compreensivo no campo da otimização combinatoria multiobjetivo que utiliza a metaheurísticas foi publicado por Andrzej Jaskiewicz em 2001 em seu livro intitulado "*Objective Metaheuristic Algorithms for Combinatorial Optimization*".

O primeiro trabalho proposto em meta heurística multiobjetivo foi apresentado por Schaffer em 1985 que apresenta o algoritmo genético avaliado por vetor (VEGA). O VEGA é apresentado como uma variação de um algoritmo genético de objetivo único cujo mecanismo de seleção foi alterado. Foi observado por (COELLO, 1999) que as soluções geradas pelo VEGA apresentaram, no modo geral, um fraco espalhamento uniforme na frente de Pareto. De fato, este algoritmo tende a ter um baixo desempenho na representação das regiões médias do grupo de pontos não-dominados.

(FONSECA; FLEMING, 1995) e (TAMAKI; KITA; KOBAYASHI, 1996) propuseram uma modificação do VEGA para melhorar a deficiência de representação das regiões ótimas de Pareto.

Recentemente, os algoritmos evolucionários têm sido adaptados para resolver problemas com múltiplos objetivos conflitantes utilizando a aproximação da frente de Pareto para tais problemas. Um tutorial completo em otimização evolucionária multiobjetivo pode ser

encontrado nos artigos (DEB; ALGORITHMS, 2001; ZITZLER; LAUMANNNS; BLEULER, 2004).

O algoritmo genético opera com um grupo de soluções candidatas manipuladas por dois operadores básicos: a *seleção* e a *variação*. A seleção está a cargo de modelar o mecanismo de reprodução das soluções aptas, enquanto a variação imita a capacidade natural de criar novos indivíduos utilizando a recombinação e a mutação. Dois objetivos, tem que ser considerados ao desenvolver um algoritmo genético multiobjetivo: o primeiro objetivo procura guiar a busca da formação do grupo de Pareto, enquanto o segundo objetivo mantém a diversidade do grupo de soluções não-dominadas.

O primeiro objetivo está relacionado diretamente com a seleção para reprodução, mais especificamente ao problema de atribuir valores de aptidão escalares na presença de múltiplos objetivos. O segundo objetivo preocupa-se com a seleção em geral devido à preocupação de evitar que a população seja composta por soluções idênticas. Pode-se citar também um último fator que influencia os dois objetivos anteriores que seria o elitismo, cuja responsabilidade reside na prevenção da perda de soluções não dominadas.

Em contraste com a otimização de objetivo único, onde as funções objetivo e de aptidão são diretamente relacionadas, a atribuição da aptidão e da seleção na otimização multiobjetivo deve considerar todos os diferentes objetivos. Entre as diferentes estratégias de atribuição de aptidão, as que são usadas com mais frequência são aquelas baseadas em aglomeração, objetivo único e dominância de Pareto.

O primeiro método, que imita o método da soma ponderada, aglomera os objetivos em uma única função objetivo parametrizada. Tais parâmetros são sistematicamente variados durante o processo de otimização para encontrar um grupo de soluções não dominadas ao invés de uma única solução de troca. Para aumentar o range de busca para todas as regiões dos grupos não-dominados, vários coeficientes dos objetivos devem ser usados. (HAJELA; LIN, 1992) propuseram uma codificação dos coeficientes na descrição das soluções. Deste modo, os coeficientes evoluem como resultado dos operadores de recombinação e mutação. A aptidão compartilhada é utilizada para alcançar a diversificação dos coeficientes. Os coeficientes são utilizados em funções lineares com transformação escalar. No trabalho de (MURATA; ISHIBUCHI; TANAKA, 1996) propôs um método onde os coeficientes são representados por um vetor aleatório usado para cada interação composto por uma única recombinação.

Os métodos baseados em um único objetivo realizam uma troca de objetivos durante a fase de seleção. A cada interação que um indivíduo for avaliado durante a fase de seleção,

potencialmente um objetivo diferente da interação anterior será utilizado para indicar se os indivíduos são aptos ou não para realizar a reprodução.

A estratégia de dominância de Pareto (ranking) é baseada na exploração parcial da população. Alguns métodos usam um ranking de dominância, isto é, o número de indivíduos pelo qual um indivíduo é dominado, para determinar o valor de aptidão; outros métodos utilizam a intensidade de dominância, onde a população é dividida em várias frentes de Pareto e sua intensidade define a que frente o indivíduo pertence.

De forma alternativa aos dois métodos anteriores, a contagem de dominância também pode ser uma estratégia, pois considera o número de indivíduos dominados por certo indivíduo. Independente da técnica utilizada, a aptidão está relacionada com toda a população, contrastando com os métodos baseados em aglomeração que calculam o valor de aptidão bruto independente dos demais indivíduos. Apenas o ranking de Pareto não garante por si só que a população irá se disseminar uniformemente sobre o grupo de pontos não dominados. De fato, no caso da seleção baseada no ranking de Pareto as populações finitas geralmente convergem para um único ótimo, tal fenômeno é denominado como flutuação genética (*genetic drift*), termo este determinado na pesquisa de (GOLDBERG; SEGREST, 1987), que implica na convergência para pequenas regiões do grupo ótimo de Pareto. Alguns autores como (SRINIVAS N., K. DEB, 1994) e (FONSECA; FLEMING, 1995) desenvolveram pesquisas para implementar soluções capazes de minimizar o efeito da flutuação genética.

A técnica de recozimento simulado em inglês (*simulated annealing* - AS) também tem sido empregada para lidar com problemas de otimização de combinatórios com múltiplos objetivos. O artigo de (SERAFINI, 1992) foi o primeiro a apresentar este método na forma de múltiplos objetivos. Em seu método Serafini demonstra que a implementação multiobjetivo não se difere muito do padrão utilizado para objetivo único, e que produz um grupo, soluções não dominadas por nenhum outro grupo gerado pelo próprio algoritmo. A técnica do recozimento simulado no modo objetivo único determina que para cada nova solução um índice de probabilidade é atribuído dependendo do valor obtido ao ser comparado com a solução atual. O valor da probabilidade se iguala a um quando a aptidão da nova solução for melhor que a solução atual e no caso da aptidão pior um valor de probabilidade menor do que é atribuído.

Em um cenário multiobjetivo três situações podem ocorrer quando comparadas a nova solução s' com a solução atual s : s' domina s , s' é dominada por s e às duas soluções s' e s são mutuamente não dominadas. No primeiro caso a probabilidade de aceitação é igual a um, no segundo caso a probabilidade de aceitação é menor que um e finalmente no terceiro caso

Serafine propõe regras diferentes que correspondem a algumas funções com transformação escalar ponderada, demonstrando que estas regras garantem que o algoritmo alcance uma das soluções ótimas de Pareto se a temperatura diminuir vagarosamente, porém esta técnica não garante a dispersão sobre todos os pontos do grupo não dominado. Para garantir a dispersão Serafini propõe uma modificação aleatória dos coeficientes temporal. Seguindo a linha de pesquisa de Serafini, (ULUNGU et al., 1999) propôs regras de aceitação multiobjetivo utilizando vetores de coeficientes pré definidos, onde cada vetor está associado com um processo de recozimento independente. Como no caso do algoritmo de (SERAFINI, 1992), o algoritmo de (ULUNGU et al., 1999) um grupo potencial de soluções ótimas de Pareto contendo todas as soluções não dominadas por qualquer outra solução gerada pelo processo de recozimento. O artigo de (SUPPAPITNARM et al., 1999) também implementa outro algoritmo baseado na técnica do recozimento simulado aplicando a problemas multiobjetivos.

(GANDIBLEUX; MEZDAOUI; FRÉVILLE, 1997) propõe em seu trabalho outra abordagem multiobjetivo utilizando a técnica de pesquisa tabu (*tabu search*). O seu método baseava-se na modificação periódica dos coeficientes a serem atribuídos nas funções objetivo com transformação escalar, e usando listas tabu, preveniu o tour as soluções já consideradas em interações anteriores. Uma segunda lista relacionava todos os coeficientes dos vetores. Na mesma área de pesquisa (HANSEN, 1998) desenvolveu uma pesquisa por tabu multiobjetivo baseado na atribuição de coeficientes para objetivos com transformação escalar. Este método emprega algumas ideias semelhantes ao do Pareto com recozimento simulado devido ao fato deste método usar o mesmo mecanismo de dispersão das soluções atingido pela modificação apropriada dos coeficientes.

2.2 Despacho Econômico Ambiental

O despacho econômico ambiental visa minimizar tanto o custo de produção de energia elétrica quanto a emissão de poluentes decorrentes da geração de eletricidade, atendendo às restrições do problema.

2.2.1 O índice de Emissões como Parâmetro para Avaliar a Contaminação Ambiental de Usinas Térmicas

A degradação ambiental, cada vez mais acelerada a nível mundial e os impactos adversos da geração de energia tem chamado cada vez mais a atenção de políticos e investigadores nas últimas décadas. Um dos principais contribuintes na emissão de gases de efeito estufa para a atmosfera, que por sua vez são os responsáveis da mudança climática é o

uso de combustíveis fósseis nas plantas geradoras de energia (BELLHOUSE; WHITTINGTON, 1996).

A produção de energia por meio de combustíveis fósseis, os processos industriais e os meios de transporte exercem grande influência sobre o meio ambiente, em virtude do desmatamento e da emissão de poluentes (CO_2 , NO_x , SO_x , C_xH_y , particulados etc.), sendo considerados as principais fontes antropogênicas da poluição.

Definem poluição como sendo a degradação do ambiente, ou seja, mudanças nas características físico-químicas ou biológicas do ar, da água ou do solo que afetam negativamente a saúde, a sobrevivência ou as atividades humanas e de outros organismos vivos (MASINDI; MUEDI, 2018).

O Protocolo de Kyoto resultou do encontro de 160 nações, em 1997, no Japão, visando reduzir as emissões de gases que causam o efeito estufa (CO_2 , CH_4 , entre outros) e, estimular o desenvolvimento de novas tecnologias e a implantação de fontes limpas de energia. Desde então, a possibilidade de comercializar as emissões (principalmente de CO_2 , resultante da queima de combustíveis fósseis, cuja utilização nos países desenvolvidos é intensiva) vem ganhando força como estratégia política.

Os poluentes do ar originam-se principalmente da combustão incompleta de combustíveis fósseis. Os poluentes atmosféricos são classificados em dois tipos: primários e secundários. Os poluentes primários são aqueles emitidos diretamente das fontes para a atmosfera, destacando-se: material particulado (fumos, poeiras, névoas); monóxido de carbono (CO); dióxido de carbono (CO_2), óxidos de nitrogênio (NO e NO_2); compostos de enxofre (SO_2 e H_2S); hidrocarbonetos; clorofluorcarbonos (HOLLADAY; LARIVIERE, 2017; JEBARAJ et al., 2017; LIU et al., 2016).

Um padrão de qualidade do ar define legalmente um limite máximo para a concentração de um componente atmosférico que garanta a proteção da saúde e do bem-estar das pessoas. Os padrões estabelecidos são baseados em estudos científicos dos efeitos produzidos por poluentes específicos e são fixados em níveis que possam propiciar uma margem de segurança adequada, sendo assim, com a degradação ambiental cada vez mais acelerada globalmente, os impactos adversos da geração de energia têm exigido mais de políticos e pesquisadores na tomada de decisões nos últimos anos (HASSLER et al., 2016; HOWARD; WAITE; MODI, 2017).

O nível de poluição do ar é medido pela quantificação das substâncias poluentes presentes no ar. considera-se poluente qualquer substância presente no ar e que pela sua concentração possa torná-lo impróprio, nocivo ou ofensivo à saúde, inconveniente ao bem-estar

público, danoso aos materiais, à fauna e à flora ou prejudicial à segurança, ao uso e gozo da propriedade e às atividades normais da comunidade.

Uma forma eficaz de reduzir emissões é usar estratégias operacionais em plantas térmicas, o que poderia ser realizado com o uso da programação de modelos matemáticos, que tenham a minimização das emissões como função objetivo ou considerar limites de emissão como restrições. o despacho de carga em sistemas de energia poderia ser formulado como um problema de otimização mono-objetivo quando os limites de emissões são tomados como restrições (MANDAL et al., 2015; SAYAH; HAMOUDA; BEKRAR, 2014).

A determinação sistemática da qualidade do ar deve ser, por problemas de ordem prática, limitada a um restrito número de poluentes, definidos em função de sua importância e dos recursos materiais e humanos disponíveis. De uma forma geral, a escolha recai sempre sobre um grupo de poluentes que servem como indicadores de qualidade do ar, consagrados universalmente: dióxido de enxofre (SO₂), poeira em suspensão, monóxido de carbono (CO), ozônio (O₃) e dióxido de nitrogênio (NO₂). A razão da escolha destes parâmetros como indicadores de qualidade do ar está ligada à sua maior frequência de ocorrência e aos efeitos adversos que causam ao meio ambiente. para o problema da mudança climática causada pelos gases de efeito estufa, a união europeia (UE) introduziu o *emission trading scheme* (ETS), que adota o “*cap-and trade*” que consiste na distribuição de permissões por meio dos governos dos países signatários do protocolo. As empresas desses países também têm um limite máximo de emissão de gases estipulado e a partir disso podem comprar e vender permissões. Sendo assim, empresas que têm um número menor de emissão permitida, podem vender a quantia restante para outras empresas (ZHANG et al., 2016).

Neste regime, as licenças de emissão são primeiro alocadas para cada instalação industrial; as instituições participantes podem comprar licenças adicionais e/ou vender seu excesso de licenças de emissão no mercado (CLEARY et al., 2016; HENNEMAN et al., 2016; KÖK; SHANG; YÜCEL, 2018). por outro lado, alguns países como a Finlândia introduziu a tributação ecológica (imposto sobre o carbono), incluindo o imposto com base tanto na quantidade do carbono contido no combustível ou da quantidade da emissão de CO₂ (HOLLADAY; LARIVIERE, 2017).

O valor da taxa de imposto sobre o carbono é decidido principalmente pelas autoridades com o duplo objetivo de reduzir a emissão de CO₂ e ao mesmo tempo promover o desenvolvimento técnico. além disso, podem ser aplicadas receitas fiscais para alcançar medidas ambientais mais avançadas (ABDILAH; MUSTAFA, 2017).

Com a introdução de mercado de emissões e tributação ecológica para o setor de energia elétrica, o desenvolvimento de métodos de tomada de decisão em matéria de comércio de emissões ou restrições de emissões está se tornando cada vez mais importantes e muitos estudos podem decidir a programação dos geradores para operação (CURTIS; LYNCH; ZUBIATE, 2016; DELARUE; VAN DEN BERGH, 2016; GRANDE-ACOSTA; ISLAS-SAMPERIO, 2017)

Embora existam muitos estudos sobre restrições de CO₂, eles se concentram principalmente no problema de decidir o nível de saída de cada gerador durante o Despacho Econômico de Carga (MA; WANG; WANG, 2017; TALAQ; EL-HAWARY; EL-HAWARY, 1994).

No entanto, para obter uma solução ótima, é importante considerar não apenas o nível de despacho de cada unidade de geração, mas também o cronograma (on/off), desde que a potência de saída mínima, as restrições, e o *start-up* influenciam na solução final do custo/emissão. Por isso, é fundamental considerar o problema de compromisso de cada unidade (UC) nos métodos de tomada de decisão. além disso, a maioria dos estudos de UC, incluindo restrições de CO₂ está se concentrando sobre a programação da solução que maximiza o lucro por unidade, mas não nas soluções ótimas de pareto na redução de CO₂ (CURTIS; LYNCH; ZUBIATE, 2016; DARYANI; ZARE, 2018).

De acordo com (PARNCUTT et al., 2019), as licenças de emissão de CO₂ são dadas geralmente por um período de um ano, enquanto o marco de tempo por programação é agendado de UC de 24 horas por vários dias, e as restrições possuem efeito apenas quando o valor das emissões de CO₂ tornam-se elevados. conforme (SHAHEEN; COHEN, 2019) acreditam que o lucro máximo é importante, porém o *trade-off* de redução de custos e CO₂ não devem ser levados em consideração.

Por isso, é importante saber o menor nível possível de emissão de CO₂ e o custo associado com base nas instalações de geração existentes. É importante focar o problema das emissões associado ao problema dos custos como um problema multiobjetivo. As soluções ótimas do Despacho Econômico de Carga e a função de utilidade marginal de emissão de CO₂ podem ser obtidas quando a combinação de geradores e do preço do combustível é determinada, e em particular o custo marginal de CO₂ será de grande utilidade para a tomada de decisões.

A captura e armazenamento de dióxido de carbono (CO₂) tem o potencial de reduzir significativamente a quantidade de CO₂ liberada na atmosfera. Às tecnologias necessárias para separar o CO₂ de outros gases e para sequestrar CO₂ são conhecidas. outros desenvolvimentos

são necessários para programar a captura e o armazenamento de CO₂ em grande escala (SHAHEEN; COHEN, 2019).

Estes custos de degradação constituem custos externos que são aplicados a terceiros, mas não são tidos em conta nem na análise custo/benefício dos empreendimentos nem sobre os preços da energia. Apesar das dificuldades associadas à valorização monetária destes efeitos externos e a incerteza relativa a eles, (RHODES et al., 2017), pode-se afirmar que eles têm um grande significado no custo total de energia e são um enorme fardo para a sociedade em geral.

2.2.2 Resolução do CONAMA

O efeito estufa é um fenômeno natural do Planeta Terra com a propriedade de absorver e reemitir parte da irradiação infravermelha emitida da Terra para o espaço, mantendo a temperatura média na superfície da Terra em torno de 14° C, sendo assim essencial para a existência de vida tal como conhecida. Caso ele não existisse, a temperatura média seria de 19° C. Os principais agentes do Efeito Estufa são o vapor d'água e o dióxido de carbono. Estudos científicos apontam que as crescentes emissões antrópicas de gases de efeito estufa, provenientes, principalmente, da queima de combustíveis fósseis em usinas termelétricas, indústria, veículos e sistemas domésticos, estão promovendo o aumento da concentração desses gases na atmosfera e, conseqüentemente, ampliando a capacidade de absorção de energia, alterando o equilíbrio energético natural do Planeta (ALVES; UTURBEY, 2010).

A Resolução CONAMA n° 382, de 26/12/2006, (CONAMA, 2006) estabelece os limites máximos de emissão de poluentes atmosféricos para fontes fixas, ou seja, a quantidade máxima de poluentes permitível de ser lançada para a atmosfera. Fonte fixa de emissão é definida como qualquer instalação, equipamento ou processo, situado em local fixo, que libere ou emita matéria para a atmosfera, por emissão pontual ou dispersa. As emissões de óxido de nitrogênio e de CO₂ são significativas em usinas térmicas a gás natural e de cogeração com biomassa a partir de resíduos de cana de açúcar. Nestes casos, (CONAMA, 2006) impõe restrições que devem ser atingidas através da utilização de equipamento de controle.

São poluentes padronizados no Brasil:

- Partículas totais em suspensão; - fumaça; - dióxido de enxofre (SO₂); - partículas inaláveis;
- Monóxido de carbono (CO); - ozônio (O₃); - dióxido de nitrogênio.

- Os padrões nacionais de qualidade do ar fixados na Resolução CONAMA N° 3 de 28/06/90¹ são apresentados na Tabela 1 (ALVES; UTURBEY, 2010; CONAMA, 2006).

Tabela 1 - Padrões de qualidade do ar no Brasil.

Poluente	Tempo de amostragem	Padrão primário $\frac{\mu\text{G}}{\text{M}^3}$ ⁽⁴⁾	Padrão Secundário $\frac{\mu\text{G}}{\text{M}^3}$ ⁽⁴⁾	Método de medição
Partículas Totais em Suspensão	24 horas ⁽¹⁾ MGA ⁽²⁾	240 80	150 60	Amostrador de grandes volumes
Dióxido de Enxofre	24 horas ⁽¹⁾ MAA ⁽³⁾	365 80	100 40	Pararosanilina
Monóxido de Carbono	1 hora ⁽¹⁾ 8 horas ⁽¹⁾	40.000 (35pmm) 10.000 (9 pmm)	40.000(35 pmm) 10.000 (9 pmm)	Infravermelho não dispersivo
Ozônio	1 hora ⁽¹⁾	160	160	Quimiluminescência
Fumaça	24 horas ⁽¹⁾ MAA ⁽³⁾	150 60	100 40	Refletância
Partículas Inaláveis	24 horas ⁽¹⁾ MAA ⁽³⁾	150 50	150 50	Separação Inercial Filtração
Dióxido de Nitrogênio	1 hora ⁽¹⁾ MAA ⁽³⁾	320 100	190 100	Quimiluminescência

(1) Não deve ser excedido mais que uma vez ao ano.

(2) Média geométrica anual (MGA).

(3) Média aritmética anual (MAA).

(4) A condição de referência para as concentrações é de 25°C e pressão de 760mmHg (1.013,2 bi libares).

Fonte: (CONAMA 2006).

2.2.3 Índice de Emissões dos Motores a Gás

Para avaliar a poluição do meio ambiente, provocada pelos motores a gás, se estabeleceu por este trabalho o índice de emissão, considerando o valor dos dados da Tabela 2. Para desenvolver a expressão matemática do índice de emissão, foram considerados os limites estabelecidos de qualidade do ar pela CONAMA e se determinou o valor ponderado de cada poluente dentro da qualidade do ar (CONAMA 1990), expresso na Tabela 2.

Tabela 2 - Dados para determinar o índice de emissão dos motores a gás.

Poluente	Padrão primário da CONAMA $\mu\text{g}/\text{m}^3$	Peso específico Permissível	Valor de influência
Partículas totais em suspensão	240	0,00592885	0,99407115
Monóxido de Carbono	40000	0,98814229	0,01185771
Dióxido de Nitrogênio	320	0,00790514	0,99209486
Hidrocarbonetos	160	0,00395257	0,99604743
Total	40480	1	3

Fonte: (MUSTAFA-MORAES et al., 2016).

Considerou-se o valor de influência das emissões de CO_2 . A equação para calcular o índice de emissões dos motores a gás é descrita em Eq. (2.3):

$$I_{emg} = CO_2 + 0,99407115MP + 0,01185771CO + 0,99209486NO_2 + 0,99604743C_xH_y \quad (2.3)$$

Como os motores a gás também emitem monóxido de nitrogênio, se decidiu incluí-los na expressão com o mesmo valor de influência que o NO_2 , segue a fórmula em Eq. (2.4):

$$I_{emg} = CO_2 + 0,99407115MP + 0,01185771CO + 0,99209486(NO_2 + NO) + 0,99604743 C_xH_y \quad (2.4)$$

A fim de calcular a taxa de emissão ou índice de emissões, todos os valores de emissões devem estar no mesmo sistema de unidades, sendo necessário realizar conversões delas de acordo com as empresas que fazem o controle dessas emissões. A Tabela 3, apresenta os valores de emissão conforme a Usina Térmica e os fatores de conversão.

Tabela 3 - Fatores de conversão.

Parâmetro	Unidades iniciais	Multiplicar por	Unidades finais
Material Particulado (MP)	mg/m^3	1	mg/m^3
Dióxido de Nitrogênio (NO_2)	mg/m^3	1	mg/m^3
Monóxido de Nitrogênio (NO)	mg/m^3	1	mg/m^3
Dióxido de Carbono (CO_2)	%	18000	mg/m^3
Monóxido de Carbono (CO)	ppm	1,25	mg/m^3
Hidrocarbonetos (C_xH_y)	%	17960	mg/m^3

Fonte: (MUSTAFA-MORAES et al., 2016).

Para realizar as conversões foram considerados os pesos moleculares dos componentes, conforme aos valores e procedimentos seguintes (ver Tabela 4):

Tabela 4 - Pesos moleculares.

Sustância	Peso molar
C	12g/mol
O ₂	32 g/mol
O	16 g/mol
CO ₂	44 g/mol
CO	28g/mol
N	14g/mol
N ₂	28g/mol
H	1g/mol
Metano CH ₄	16g/mol
Hexano C ₆ H ₁₄	86g/mol

Fonte: (GREEN 2007, ALBRIGHT 2008).

$$mg/m^3 = \frac{ppm \times PM}{24,45} \quad (2.5)$$

Assim, a expressão para calcular o índice de emissão dos motores a gás é descrita em Eq. (2.6):

$$I_{emg} = 18000 CO_2 + 0,99407115MP + 0,01185771 * 1,25CO + 0,99209486(NO_2 + NO) + 0,99604743 * 17960 C_xH_y \text{ em } mg/m^3. \quad (2.6)$$

Na expressão (4.4) o CO₂ e os C_xH_y ficam expressos em %, o CO em ppm e os demais dados em mg /m³.

Na Tabela 5, são apresentadas as emissões típicas de um motor a gás da Usina em Manaus.

Tabela 5 - Emissões Típicas dos motores a gás.

Emissões típicas de um Motor a gás (UGGN 12)	U originais	a 3%mg/m ³
Material Particulado mg/m ³	76,57	76,57
Dióxido de Nitrogênio mg/m ³	315,07	315,07
Oxigênio % a mg/m ³	12,3	80490,7975
Dióxido de Carbono (CO ₂) % a mg/m ³	4,8	86400
Monóxido de carbono CO ppm a mg/m ³	286	327,525562
Monóxido de Nitrogênio mg/m ³	105	105
Hidrocarbonetos (C _x H _y) de ppm a mg/m ³	861,64	1688,8144
Óxidos de Nitrogênio (NO _x como NO ₂) ppm a (mg/m ³)	213	400,44

Fonte: (MUSTAFA-MORAES et al., 2016).

2.2.4 Índice de Emissões dos Motores a HFO

Neste caso, o procedimento desenvolvido foi o mesmo que para os motores a gás, porém a combustão do HFO gera produtos como CO_2 , NO_x , SO_x , CO , HC e materiais particulados. Os gases de escape são emitidos para a atmosfera a partir dos escapamentos das embarcações e se diluem com ar ambiente. Estas emissões podem alterar regional e globalmente a composição da atmosfera, impactando no clima (EYRING, 2005). (ver Tabela 6).

Tabela 6 - Dados para determinar o índice de emissão dos motores a HFO.

Poluente	Padrão primário da CONAMA $\mu g/m^3$	Peso específico permissível	Valor de influência
Partículas totais em suspensão	240	0,0059	0,9941
Monóxido de Carbono	40000	0,9735	0,0265
Dióxido de Nitrogênio	320	0,0078	0,9922
Dióxido de Enxofre	365	0,0089	0,9911
Hidrocarbonetos	160	0,0039	0,9961
TOTAL	41085	1	4

Fonte: (MUSTAFA-MORAES et al., 2016).

A Tabela 7 apresenta os valores de conversão:

Tabela 7 - Fatores de conversão no caso dos motores a HFO.

Parâmetro	Unidades iniciais	Multiplicar por	Unidades finais
Material Particulado (MP)	mg/m^3	1	mg/m^3
Dióxido de Nitrogênio (NO_2)	mg/m^3	1	mg/m^3
Monóxido de Nitrogênio (NO)	mg/m^3	1	mg/m^3
Dióxido de Carbono (CO_2)	%	18000	mg/m^3
Monóxido de Carbono (CO)	ppm	1,25	mg/m^3
Dióxido de Enxofre	mg/m^3	1	mg/m^3
Hidrocarbonetos (C_xH_y)	%	17960	mg/m^3

Fonte: (MUSTAFA-MORAES et al., 2016).

Onde,

$$I_{emHFO} = 18000 \times CO_2 + 0,9941MP + 1,25 \times 0,0265CO + 0,992(NO_2 + NO) + 0,991SO_2 + 0,9961 * 17960 C_x H_y \quad \text{em } g/m^3 \quad (2.7)$$

Na Tabela 8, são apresentadas as emissões típicas de um motor MAN a HFO da Usina em Manaus.

Tabela 8 - Emissões típicas de um motor MAN a HFO.

Emissões Típicas de um Motor a HFO (MAN 1)	U originais	a 7% mg/m³	a 3% mg/m³
Material Particulado mg/m ³	156,65	156,65	201,407143
Dióxido de Enxofre mg/m ³	287,42	287,42	369,54
Oxigênio % a mg/m ³	13,7	179304,703	230534,619
Dióxido de Nitrogênio mg/m ³	315,07	315,07	405,09
Dióxido de Carbono (CO ₂) % a mg/m ³	5,5	98977,5051	127256,792
Monóxido de carbono CO ppm a mg/m ³	66,66	76,3386503	98,1496933
Monóxido de Nitrogênio mg/m ³	1167	1167	1500,42857
Óxidos de Nitrogênio (NO _x como NO ₂) (mg/ m ³)	1843	1843	2369,57143
Hidrocarbonetos Totais (C _x H _y) de % a (mg/ m ³)	0,03	588	756

Fonte: (MUSTAFA-MORAES et al., 2016)

2.3 Energias Renováveis

À medida que aumenta a preocupação com o aquecimento global, a fonte de energia renovável se torna uma fonte de energia mais significativa. Essas fontes de energia, são apresentadas como principal alternativa para atender as necessidades da sociedade, considerando a qualidade e segurança de atendimento da demanda de eletricidade e diminuição dos impactos ambientais, ocasionados pelo intenso consumo de energia (SANTANA et al., 2020).

De acordo com (REN21, 2019), as energias renováveis cresceram rapidamente no setor de energia, enquanto muito menos avanços ocorreram nos setores de aquecimento e transporte. A energia renovável teve outro ano recorde em 2019, à medida que a capacidade instalada de energia cresceu mais de 200 gigawatts (GW) - o maior aumento de sua história. As instalações de capacidade e o investimento continuaram a se espalhar por todos os cantos do mundo, e os sistemas de energia renovável distribuída proporcionaram às famílias adicionais em países em desenvolvimento e emergentes acesso a eletricidade e serviços. Também durante o ano, o setor privado assinou contratos de compra de energia (PPAs) para uma quantidade recorde de capacidade de energia renovável, impulsionada principalmente por reduções contínuas de custos em algumas tecnologias. Entre o público em geral, o apoio às energias renováveis continuou a avançar juntamente com a crescente conscientização sobre os múltiplos benefícios das energias renováveis, incluindo a redução de dióxido de carbono (CO₂) e outras emissões de gases de efeito estufa.

As fontes convencionais de energia baseadas em petróleo, carvão e gás natural provaram ser motores altamente eficazes do progresso econômico. No entanto, com o rápido esgotamento

das fontes convencionais de energia e o aumento da demanda por energia, o consumo mundial de energia primária cresceu 1,8% em 2012 (ABAS; KALAIR; KHAN, 2015; AHMADI et al., 2018). Devido a certas questões ambientais, muitas organizações relacionadas incentivam a pesquisa intensiva para usinas de energia mais eficientes e verdes, utilizando tecnologia. Visto que as preocupações com a proteção ambiental estão aumentando, tanto as tecnologias de combustível limpo quanto as novas energias estão sendo intensamente buscadas e investigadas. Na verdade, os preços dos combustíveis fósseis e das energias renováveis, os custos sociais e ambientais estão se movendo em direções opostas e os mecanismos econômicos e políticos necessários para apoiar a ampla disseminação de mercados sustentáveis para sistemas de energia renovável estão evoluindo rapidamente. É claro que o crescimento futuro do setor de energia é principalmente no novo regime de renováveis. Portanto, mudar para a energia renovável pode nos ajudar a cumprir os objetivos duplos de redução das emissões de gases de efeito estufa, limitando assim os impactos climáticos e climáticos extremos futuros e garantindo o fornecimento confiável, oportuno e econômico de energia. O surgimento de tais energias nos últimos anos tem impulsionado amplamente o interesse entre investigadores, políticos e líderes da indústria em compreender a viabilidade econômica da nova fonte de energia e investir em energia renovável pode ter dividendos significativos para a nossa segurança energética (AHMADI et al., 2018; KABIR et al., 2018).

2.3.1 Energia Solar Fotovoltaica


Entre as fontes de energia renováveis, a geração fotovoltaica está atraindo uma quantidade crescente de interesse político e comercial. Nesse contexto, as fontes renováveis de geração de energia são mais apropriadas, pois se bem gerenciadas, possibilitam que sua exploração seja ilimitada, já que sua disponibilidade não é reduzida conforme o uso (ELLABBAN; ABU-RUB; BLAABJERG, 2014; FOXON, 2017).

A energia solar é uma das indústrias que mais crescem em todo o mundo, e para manter esse ritmo, novos desenvolvimentos têm surgido no que diz respeito ao uso de materiais, consumo de energia para a fabricação desses materiais, desenho industrial de dispositivos, produção tecnologias, bem como novos conceitos para aumentar a eficiência global das células (INFIELD; FRERIS, 2020).

Pode-se observar que as definições apresentadas pelos autores sobre energia solar fotovoltaica possuem termos em comum, sendo eles: “Eletricidade”, “radiação solar”, “geração direta”, “conversão”. Assim, podemos adotar como conceito de energia solar fotovoltaica a

seguinte definição: eletricidade obtida diretamente da conversão da energia solar. A conversão da radiação solar em eletricidade ocorre devido ao efeito fotovoltaico, sendo observado pela primeira vez por Becquerel em 1839. Esse efeito ocorre em materiais conhecidos como semicondutores, que apresentam duas bandas de energia, em uma delas é permitida a presença de elétrons (valência ruim) e na outra não há presença deles, ou seja, a banda está completamente “vazia” (banda de condução), ver Figura 2.

Figura 2 - Banda de valência, gap (GAP) e banda de condução: isolador, condutor e semicondutor.



Fonte: www.livrozilla.com

A função da luz solar no efeito fotovoltaico é fornecer uma quantidade de energia ao elétron mais externo para ele poder passar da banda de valência para a banda de condução no material, gerando eletricidade. Assim como (LÓPEZ et al., 2020) no caso do silício, especificamente, é necessário 1,12 eV (eletro volts) para que os elétrons ultrapassem o GAP. Além disso, de acordo com (JANKE et al., 2020), o material semicondutor deve ser capaz de absorver grande parte do espectro solar. Praticamente todos os dispositivos fotovoltaicos incorporam uma junção PN em um semicondutor, que através de uma fotovoltaica é desenvolvida. Esses dispositivos também são conhecidos como células solares ou células fotovoltaicas (SAMPAIO; GONZÁLEZ, 2017).

As células fotovoltaicas possuem a capacidade de converter a luz solar em eletricidade excitando os elétrons do material semicondutor e gerando corrente elétrica, no entanto, a resposta ao espectro solar é altamente dependente do band-gap do material semicondutor da célula, sendo mais eficiente a conversão quando as componentes espectrais da radiação solar estão próximas da energia do band-gap. Contudo, apenas uma parte estreita do espectro solar é

absorvida e aproveitada para excitar os elétrons, sendo a outra parte do espectro solar não absorvida pelo semicondutor. Dentre os elétrons excitados, existem aqueles que absorvem muito mais energia do que o necessário para que ocorra a geração de eletricidade, tendo que dissipar a energia excedente na forma de calor num processo conhecido como “termalização”, aumentando a resistência interna e diminuindo sua eficiência causando uma possível redução a vida útil da célula (DINIZ et al., 2018).

Um típico sistema de energia solar fotovoltaica consiste em quatro elementos básicos: módulos ou painéis fotovoltaicos, inversores, controladores de carga e baterias, caso necessário.

Os sistemas fotovoltaicos são uma forma de geração de energia limpa, e algumas de suas vantagens são a modularidade, a mobilidade, a facilidade de se instalar e sua longa expectativa de vida, podendo chegar a vinte e cinco anos (SINGH, 2016). Devido a esta facilidade, o crescimento do sistema fotovoltaico para geração de energia elétrica é um dos mais promissores no domínio das energias renováveis. Isto é uma tendência que deverá continuar nos próximos anos (AL-MAAMARY; KAZEM; CHAICHAN, 2017).

Segundo REN21 (2019), a energia solar (FV) após um ano de demanda estável, o mercado de energia solar (FV) aumentou 12% em 2019 para um recorde de 115 GW (corrente contínua), para um total de 627 GW. A década terminou com forte demanda na Europa, Estados Unidos e mercados emergentes ao redor do mundo, mais do que compensando um declínio substancial na China. Sem incluir a China, o mercado global cresceu cerca de 44%. A China continuou a dominar o mercado mundial, bem como a manufatura, tendo uma influência significativa em ambos.

2.3.1.1 Sistemas Fotovoltaicos Autônomos ou Isolados

Os sistemas fotovoltaicos autônomos ou isolados foram os primeiros sistemas a operarem comercialmente, são utilizados principalmente em locais onde não há fornecimento de energia através da rede pública ou em locais e aplicações nas quais não existem razões técnicas ou econômicas para criá-la. Logo esses sistemas são normalmente mais caros em razão dos acumuladores de energia, que possuem alto custo de investimento e manutenção (SAITOV et al., 2020).


Nesse mesmo contexto os sistemas isolados podem ainda ser divididos em sistemas com armazenamento e sem armazenamento. Dessa forma para os sistemas com armazenamento em baterias, usa-se o “controlador de carga”, dispositivo responsável pelo controle de carga e

descarga das baterias, prolongando a vida útil e aumentando a confiabilidade do sistema (GURUNG; QIAO, 2018).

Sistemas que não possuem necessidade de armazenamento são aqueles em que as cargas consomem toda a energia produzida pelos painéis, por exemplo, sistemas de irrigação e bombeamento (WATSON et al., 2018). Outro ponto a se destacar desse sistema, que geralmente são de baixa e média potência, tensão nominal de 12V, 24V ou 48V, para o suprimento de potência às comunidades isoladas e não atendidas pela rede elétrica pública. Também são utilizados para bombeamento de água, centrais ou repetidoras de serviços de telecomunicações, sistemas de sinalização, dentre outros (HUSSAIN et al., 2017).

Conforme ilustração mostrada na Figura 3, é composta conforme a demanda, por um ou vários módulos solares conectados em série, ou paralelo, tendo um ou mais controladores de carga, podendo-se utilizar baterias como armazenadores de energia elétrica. Além disso, os sistemas podem ainda possuir cargas em corrente contínua (CC) ou em corrente alternada (CA), sendo necessário para o segundo caso, a utilização de inversores de frequência (CARRIÇO et al., 2018). A Figura 3 mostra as opções de ligação de sistemas em função das cargas.

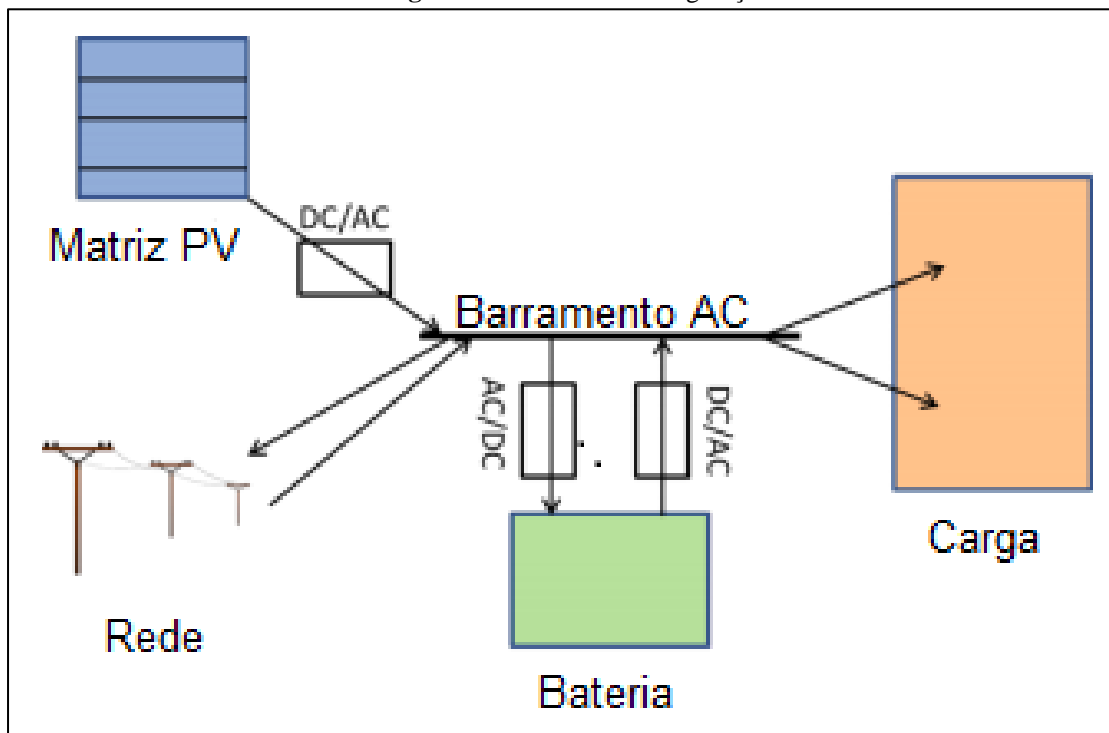
Figura 3 - Diagrama de sistema fotovoltaico autônomo ou isolado em função da carga utilizada.



Fonte: (CRESESB, 2006).

A eficiência de carregamento é conhecida como eficiência CA para CC, com a suposição de que a energia vem de uma fonte CA. A eficiência de descarga é referida como eficiência DC para AC, com a suposição de que a energia DC deve ser convertida para atender a uma carga AC. Existem outras configurações, como onde a energia flui para a bateria de uma fonte DC (matriz fotovoltaica) por meio de um ou dois controladores de carregamento ou a energia vem de uma fonte AC, é invertida e enviada por meio de um controlador de carregamento para a bateria (DIORIO et al., 2015; GRANQVIST; NIKLASSON, 2018; OPIYO, 2019; SHEKHAR et al., 2017). A Figura 4, ilustra a configuração modelada.

Figura 4 - Modelo de Configuração.



Fonte: (DIORIO et al., 2015).

2.3.1.2 Sistema fotovoltaico conectado à rede

A demanda de energia está aumentando dia a dia devido ao aumento da população, urbanização e industrialização. Os recursos de energia renovável são alternativas às nossas fontes de energia tradicionais que são limitadas e vão expirar. Recursos de energia limpa, como solar, eólica e hídrica, tornaram-se cada vez mais populares, principalmente porque não produzem emissões e são inesgotáveis. O efeito da energia fotovoltaica pode ser considerado um recurso sustentável essencial devido à abundância de energia solar radiante e à sustentabilidade, portanto, o sistema fotovoltaico conectado à rede é amplamente utilizado, embora a energia solar esteja disponível em abundância e gratuitamente, o custo das células

fotovoltaicas é muito alto. Portanto, o investimento inicial em energia solar será muito alto. O elemento básico de um sistema fotovoltaico é a célula solar, que converte a irradiância solar em corrente contínua. A interconexão da rede do sistema fotovoltaico requer um conversor eficiente para converter a baixa tensão DC em AC (MOHAMMED; MOHAMMED; IBRAHIM, 2017).

Esclarecendo ainda que um sistema fotovoltaico conectado à rede (SFCR) pode ser definido como um conjunto de equipamentos que permitem transformar energia solar em energia elétrica e sincronizar com a rede elétrica de alta ou baixa tensão, dependendo da aplicação. Entretanto, existem duas categorias de instalações fotovoltaicas conectadas à rede são elas as grandes centrais fotovoltaicas e as unidades localizadas diretamente no ponto de consumo e muitas vezes, sobre áreas já ocupadas como residências, edifícios e indústrias (TORRES et al., 2019; VILLALVA, 2010).

A propósito da Agência Nacional de Energia Elétrica que em 24 de novembro de 2015, aprovou a resolução normativa nº 687, alterando a resolução normativa nº 482 de 17 de abril de 2012 e os módulos 1 e 3 dos procedimentos de distribuição – (PRODIST), onde define as regras para a geração distribuída a ser integrada à rede: (DE ANDRADE et al., 2020).

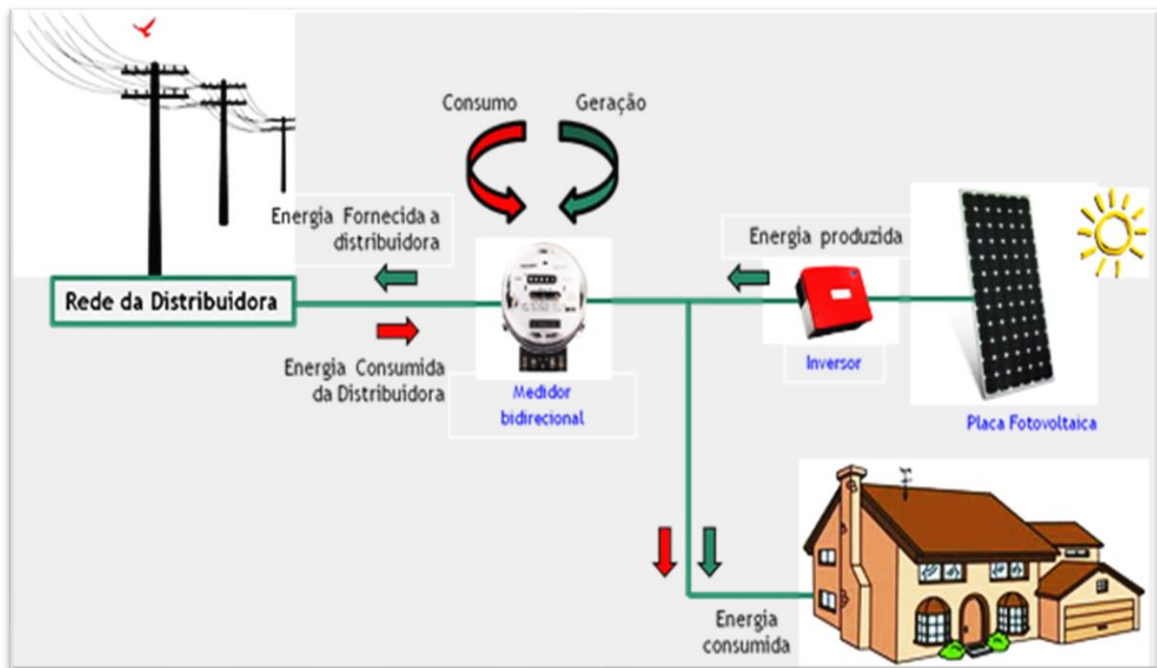
- Microgeração distribuída: central geradora de energia elétrica com potência instalada menor ou igual a 100 KW. Sua geração tem que ser derivada de energia hidráulica, solar, biomassa, eólica, conectadas à rede de distribuição por meio de unidades consumidoras.
- Minigeração distribuída: central geradora de energia elétrica com potência instalada superior a 100 KW e menor ou igual a 1 MW. Sua geração tem que ser derivada de energia hidráulica, solar, biomassa ou eólica, conectadas à rede de distribuição por meio de unidades consumidoras.
- Sistema de compensação de energia elétrica: o excedente de energia produzida por uma unidade, é cedida por meio de empréstimo gratuito à concessionária. Posteriormente, se a unidade não gerar energia suficiente para o uso, será descontado do crédito que a unidade tem com a distribuidora.

Deste modo, sistemas de micro e minigeração fotovoltaicos, providos por consumidores em geral, poderão ser integrados à rede elétrica diretamente na baixa tensão, através de inversores monofásicos e nos pontos de consumo. Por outro lado, no caso de usinas fotovoltaicas, a integração à rede elétrica primária será através de inversores trifásicos e transformadores elevadores. Dessa forma é provável que ocorra o aumento da oferta de energia elétrica no Brasil (BARONI et al., 2021; VARGAS; MENDES; BATISTA, 2018). Os sistemas

de geração distribuída, baseados nessa tecnologia, são muito adequados para a instalação em qualquer local onde haja incidência da luz solar e particularmente no Brasil, praticamente todo o seu território poderá utilizar essa categoria de geração.

É importante destacar que as usinas de geração fotovoltaica para integração à rede são compostas por determinada quantidade de módulos solares, em arranjos em série ou paralelo, formando filas ou “strings” para o suprimento adequado de potência, em geral, da ordem de MW. No que lhe concerne a saída do gerador fotovoltaico é conectada a um inversor ou central de inversores, conforme ilustração de esquema mostrado na Figura 5. Os módulos solares para conexão à rede têm, geralmente, mais de 36 células, pois os valores requeridos de tensão de saída nesses geradores são maiores que nos geradores fotovoltaico autônomos (BARONI et al., 2021). A figura 5 mostra o diagrama de um sistema fotovoltaico conectado à rede elétrica.

Figura 5 - Diagrama de um sistema fotovoltaico conectado à rede.



Fonte: (VIRIDIAN, 2015).

2.3.1.3 Sistemas Híbridos


Os sistemas híbridos consistem em, pelo menos, duas tecnologias de energia renovável e/ou armazenamento de energia, que oferecem flexibilidade à rede, bem como, reduzem custos e fornecem benefícios técnicos (incluindo fatores de capacidade mais elevados) (HALABI; MEKHILEF, 2018).

Os sistemas híbridos são empregados em sistemas de médio a grande porte destinados a atender um número maior de usuários. Por trabalhar com cargas em corrente alternada é necessário um inversor, devido à complexidade de arranjos e multiplicidade de opções, a forma de otimização do sistema torna-se um estudo particular a cada caso.

Existem várias configurações possíveis, assim como estratégias de uso de cada fonte de energia, observando a figura 6, nota-se um sistema híbrido que combina numa única instalação várias fontes de energia ligadas de forma autônoma, ou seja, ainda que interligadas, cada fonte possui sua própria capacidade de produção de energia para suprir a demanda pretendida.

O referido sistema utiliza a inserção de fontes renováveis e fontes fósseis para a produção de energia, e podem incluir baterias para acumular a energia produzida. Este sistema é desconectado da rede convencional. Portanto, com a utilização de várias formas de geração de energia elétrica, aumenta a complexidade do sistema e exige a otimização do uso de cada uma das fontes. Sendo necessário realizar um controle de todas as fontes para haver um melhor aproveitamento (eficiência) na entrega da energia para o cliente. A potência destes sistemas varia entre 10 kW e 200 kW (LOPES; FERNANDES; MUCHALUAT-SAADE, 2015). A figura 6 mostra o diagrama de um sistema híbrido.

Figura 6 - Diagrama de um sistema Híbrido.



Fonte: www.google.com

2.4 Usinas Termoelétricas

As termelétricas são “instalações de produção de energia elétrica a partir do aproveitamento da energia térmica obtida pela combustão de um combustível fóssil ou biomassa.”, essas instalações são usadas como alternativas (*backup*) às hidrelétricas. Quando ligadas produzem energia elétrica a partir da energia liberada em forma de calor, a queima dos combustíveis em sua maioria libera resíduos poluentes na atmosfera, causando diversos impactos ambientais.

Apesar das termoelétricas funcionarem com diferentes tipos de combustíveis, seu funcionamento é praticamente o mesmo: o processo é feito em uma câmara de combustão, e o calor aquece a caldeira de água, causando vapor em alta pressão. Essa pressão, move as pás da turbina conectadas ao gerador de eletricidade, fazendo com que ele funcione. Por fim, o vapor é resfriado, voltando à caldeira em estado líquido.

A construção de termoelétrica em locais próximos aos centros consumidores é considerada uma de suas vantagens, permitindo economizar com as redes de transmissão, conseqüentemente evitando falhas e desperdício de energia elétrica. Outra de suas vantagens é a produção constante de energia por não depender das situações climáticas, o que não ocorre com as hidrelétricas que perdem capacidade em períodos menos chuvosos.

Embora as termoelétricas apresentem inúmeras vantagens, ela possui as seguintes desvantagens:

- As fontes de energia utilizadas pelas termelétricas não são renováveis, o que acaba gerando preocupação em relação à disponibilidade desses recursos na natureza a médio e longo prazo;
- Ela é responsável por emissão de muitos poluentes durante a produção de eletricidade, causando o efeito estufa;
- A queima do combustível fóssil acaba emitindo toneladas de dióxido de carbono para a atmosfera, se for uma usina nuclear causa lixos radioativos.
- Mais o grande vilão é o preço final que chega para os consumidores, pois são valores maiores, se comparados com as outras fontes de geração de eletricidade.

2.5 Considerações Finais do Capítulo II

Neste capítulo foram descritos os conceitos básicos e definições relacionadas as técnicas de otimização, despacho econômico ambiental, energia renováveis com uma abordagem focada

em energia solar fotovoltaica e usinas termoelétricas com suas vantagens e desvantagens para o meio ambiente.

As pesquisas relacionadas ao DEA, são estudados com grande interesse devido a sua grande repercussão social, existindo inúmeros pesquisadores de diferentes países dedicados a encontrar soluções para otimizar o problema do DEA. No capítulo seguinte serão descritos modelos matemáticos para resolução do problema do DEA com o propósito de minimizar dois objetivos que são: o custo total de combustível e a quantidade de emissões de poluentes na natureza.

CAPÍTULO III

3 MODELO MATEMÁTICO PARA APLICAÇÃO DA METODOLOGIA

É importante destacar a otimização do problema de multicritério DEA, que contemplam duas funções objetivo: função de consumo de combustível (F2) e função de custo ambiental (F3). Os coeficientes da função objetivo são obtidos por meio de técnicas de ajuste baseadas em testes de desempenho do motor.

3.1 Modelo matemático de geração por usina solar (F1)

Um modelo para a representação da geração em uma planta solar, Solar Power Plant (SPP), é descrita na Eq.(3.1) (BRINI; ABDALLAH; OUALI, 2009a):

$$F_1(Pgs_j) = P_{rated} \left(1 + (T_{ref} - T_{amb}) * \alpha \right) * \frac{S_i}{1000} \quad (3.1)$$

Onde:

F_1 = potência da usina solar

Pgs_j = potência do gerador solar

P_{rated} = potência nominal;

T_{ref} = temperatura de referência;

T_{amb} = temperatura ambiente;

α = coeficiente de temperatura; e

S_i = radiação solar incidente.

Com SPP usado na geração de energia, a energia solar empregada é descrita pela Eq.(3.2) (BRINI; ABDALLAH; OUALI, 2009a):

$$Ss = \sum_{j=1}^m F_1(Pgs_j) \times Us_j \quad (3.2)$$

Onde, Pgs_j é a energia disponível no j^{th} SPP e Us_j indica o status do j^{th} SPP que é 1 (LIGADO) ou 0 (DESLIGADO). O custo do SPP é descrita na Eq. (3.3) (BRINI; ABDALLAH; OUALI, 2009b):

$$Sc = \sum_{j=1}^m PUCost_j \times F_1(Pgs_j) \times Us_j \quad (3.3)$$

onde $PUCost_j$ é o custo unitário do j^{th} de SPP.

3.2 Modelo Matemático de Custo de Termelétricas (F2)

O objetivo principal do Despacho Econômico de Carga de carga (DEC) é determinar a distribuição ótima da demanda de energia entre as unidades geradoras comprometidas, minimizando o custo operacional total e satisfazendo um conjunto de restrições de igualdade e desigualdade, que é uma das principais tarefas de otimização em sistemas de energia. Devido à responsabilidade ambiental, o DEC torna-se um problema de otimização multicritério do Despacho Econômico de Carga ambiental (DEA), visando reduzir a emissão de gases poluentes na atmosfera (ZHU, 2015).

A equação do consumo de combustível de cada unidade geradora é representada por uma função quadrática descrita na Eq. (3.4), considerando a potência de saída do gerador P_i , dada em \$/h, como:

$$f_i(P_i) = a_i + b_i P_i + c_i P_i^2 \quad (3.4)$$

onde a_i , b_i e c_i representam os coeficientes de consumo de combustível de cada i -ésima unidade geradora.


O problema de minimizar o custo total da usina térmica está descrita em Eq. (3.5).

$$\text{Min } F_2(P_i) = \sum_{i=1}^N f_i(P_i) \quad (3.5)$$

onde N é o total de unidades geradoras da usina térmica e P_i a potência de saída de cada unidade geradora.

A Figura 7 ilustra a curva de consumo de combustível sem efeito do ponto de válvula, observando que não é a representação da curva de eficiência do motor.

Figura 7 - Consumo de combustível sem efeito de ponto de válvula.



Fonte: Adaptado de (QIN et al., 2017).

Os efeitos da trefilação, que ocorrem quando cada válvula de admissão de vapor em uma turbina começa a abrir, produzem um efeito ondulante na curva da unidade. Um aumento acentuado na perda de combustível é adicionado à curva de custo de combustível devido aos efeitos da trefilação quando a válvula de admissão de vapor começa a abrir. Este procedimento é denominado efeito de ponto de válvula (BASU, 2014).

3.3 Modelo Matemático das Emissões em Usinas Térmicas (F3)

A função de emissão total da usina térmica, formulada na Eq. (3.6), relaciona as emissões com a potência gerada por cada unidade geradora (MIRANDA; HANG, 2005). Esta função representa a emissão de SO₂ e NO_x em kg/h que pode ser expressa da seguinte forma: (BASU, 2014; DHAMANDA et al., 2013):

$$h_i(P_i) = \alpha_i + \beta_i P_i + \gamma_i P_i^2 \quad (3.6)$$

Onde α_i , β_i e γ_i representam os coeficientes de emissão de cada unidade geradora.

A equação (3.7) representa a minimização total do problema UTE.

$$\text{Min } F_3(P_i) = \sum_{i=1}^N h_i(P_i) \quad (3.7)$$

Onde N é o total de unidades geradoras da usina térmica e P_i a potência de saída de cada unidade geradora.

3.4 Restrições de Despacho Econômico de Carga

Despacho econômico de carga é o estudo do uso ótimo das unidades geradoras do sistema elétrico. Seu objetivo é a minimização do custo de produção da energia elétrica, satisfazendo as condições de operações do sistema, do estudo resultam as potências de saída de cada unidade geradora.

3.4.1 Restrição de Equilíbrio de Potência

A potência nominal é definida pelos limites inferior e superior de cada unidade geradora. Na Eq. (3.8) a restrição de igualdade de equilíbrio de potência é formulada (DHAMANDA et al., 2013; NWULU; XIA, 2015):

$$\sum_{i=1}^n P_i - P^D - P^L = 0 \quad (3.8)$$

Onde P_i é a potência nominal de cada unidade geradora, P^D é a demanda de potência, P^L são as perdas na transmissão.

Portanto, a geração total deve ser igual à demanda de energia mais as perdas reais nas linhas de transmissão, conforme descrita em Eq. (3.9):

$$\sum_{i=1}^n P_i = P^D + P^L \quad (3.9)$$

A restrição de potência total gerada na Eq. (3.8) deve levar em consideração a geração de SPP, descrita na Eq. (3.10) (KHAN et al., 2015a).

$$P^D + P^L - \sum_{i=1}^n P_i - \sum_{j=1}^m P g s_j \times U s_j = 0 \quad (3.10)$$

O dimensionamento do P^L é igual à soma das perdas versus potência, que apresenta restrições de igualdade na potência ativa e reativa em cada barra, conforme Eq. (3.11) (WANG; SINGH, 2007):

$$P^L = \sum_{i=1}^n B_i P_i^2 \quad (3.11)$$

As perdas de transmissão são definidas como uma função da saída do gerador, derivando os coeficientes de perda de Kron da fórmula de perda de Kron's, descritas em Eq. (3.12) (HUANG et al., 2018):

$$P^L = \sum_{i=1}^n \sum_{j=1}^n P_j B_{ij} P_j + \sum_{i=1}^n B_{oi} P_j + B_{oo} \quad (3.12)$$

Onde B_{ij} , B_{oi} e B_{oo} são os coeficientes de perda de transmissão na rede, n é o número de geradores. Os coeficientes B podem ser determinados com certa precisão quando as condições reais de operação estão próximas do caso base (GITIZADEH; GHAVIDEL, 2014).

3.4.2 Restrição de Geração

A potência de cada unidade geradora é determinada pelos limites inferior e superior conforme Eq. (3.13) (EL-SHORBAGY; MOUSA, 2017):

$$P_{min.i} \leq P_i \leq P_{max.i} \quad (3.13)$$

Onde P_i é a potência de saída de cada unidade geradora, $P_{min.i}$ e $P_{max.i}$ é a potência mínima e máxima de cada unidade geradora.

Outra restrição que deve ser atendida em um sistema híbrido com energia renovável é utilizar no máximo 80% da capacidade máxima instalada do SPP, devido à sua instabilidade de geração, conforme apresentado na Eq. (3.14) (KHAN et al., 2015a):

$$\sum_{j=1}^m P_{gsj} \times U_{sj} \leq 0.7 \times SPP \quad (3.14)$$

3.5 Problema de Otimização

Para este problema, a geração de energia é calculada analisando a capacidade instalada do PPS, utilizando um valor máximo de 80% da geração total, e então o custo dessa geração de energia no PPS é calculado, aplicando a função $F_I(P_{gsj})(j)$ descrito na Eq. (3.1). A demanda pendente é resolvida minimizando a função multicritério, (3.14):

$$Min(P_i) = [F_2(P_i), F_3(P_i)] \quad (3.14)$$

Onde $F2(P_i)$, $F3(P_i)$ são as funções objetivo a serem otimizadas considerando as restrições de potência nominal (P_i) de cada unidade geradora descrita em (3.13).

3.6 Formulação do Custo Incremental

A formulação de custo de combustível incremental (\$/MWh) é descrita na Eq. (3.15) (DHAMANDA et al., 2013; NASCIMENTO et al., 2017a) e apresentada na Figura 8:

$$IC_i = (2 \cdot a_i \cdot P_{gi} + b_i) \quad (3.15)$$

Onde:

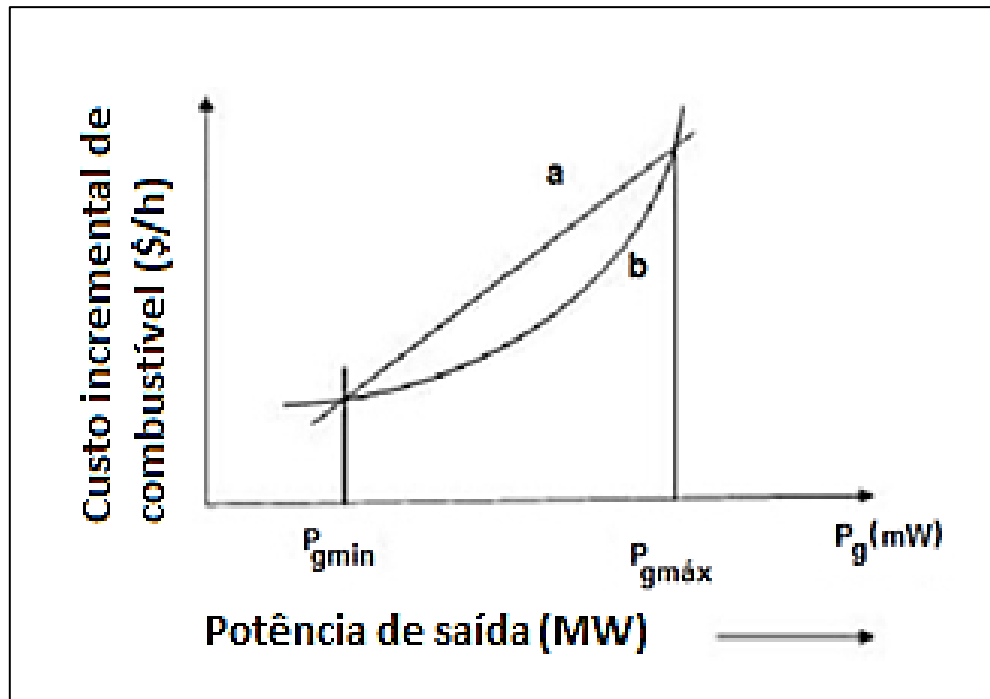
IC_i = é o custo de combustível incremental;

a_i = é a curva de custo incremental real;

b_i = é a curva de custo incremental aproximada (linear);

P_{gi} = é a geração total de energia.

Figura 8 - Curva de custo incremental.



Fonte: (NASCIMENTO et al., 2017b).

3.7 Considerações Finais do Capítulo III

Neste capítulo foram descritas as diferentes abordagens matemáticas na aplicação da metodologia para resolução do problema DEA, incluindo o modelo matemático de geração por usinas solares fotovoltaicas e as diferentes equações e restrições para desenvolver o DEA, estas equações e restrições compõem o modelo matemático e serão utilizadas nos capítulos seguintes. Destaca-se ainda que os coeficientes da função objetivo são obtidos por meio de técnicas de ajuste baseadas em testes de desempenho do motor e que as funções de custo e emissões são funções quadráticas da potência.

CAPÍTULO IV

4 TÉCNICAS METAHEURÍSTICAS


As metaheurísticas são implementações que guiam outras heurísticas, ou seja, procedimentos computacionais, usualmente de busca local, explorando o espaço de soluções além do ótimo local. As metaheurísticas consideram boas características das soluções encontradas para explorar novas regiões promissoras.

4.1 Algoritmo de Otimização Ant Lion Optimizer

Em 2015, um algoritmo inspirado na natureza chamado de formiga leão do inglês *Ant Lion Optimizer* (ALO) foi proposto (MIRJALILI, 2015). A principal metodologia do algoritmo ALO deriva da estratégia de forrageamento de larvas de anfílions. É também um algoritmo de população que simula o comportamento de caça da formiga leão. Ele usa cinco etapas: passeio aleatório; construção de armadilhas; captura de formigas e presas; remoção de presas e restauração de armadilhas (MIRJALILI, 2015).


Os estágios larvais e adultos são dois estágios importantes no ciclo de vida do ALO. O ALO caça na fase larval e procria na fase adulta. O período larval é a base do algoritmo ALO. O ALO cava a fossa em forma de cone na areia, seguindo um caminho circular e retirando a areia com as suas mandíbulas. Depois de construir a armadilha, a larva espera pela presa. O tamanho da armadilha varia com o nível de fome da formiga e tamanho da lua (KAMBOJ; BHADORIA; BATH, 2017a; TRIVEDI; JANGIR; PARMAR, 2016). Ver Figura 9 e 10.

Figura 9 - Armadilhas em forma de cone e comportamento de caça da formiga leão.



Fonte: (KAMBOJ; BHADORIA; BATH, 2017b).

Figura 10 - Armadilhas em forma de cone e comportamento de caça da formiga leão.



Fonte: (MIRJALILI, 2015).

O algoritmo ALO também pode ser usado para otimizar o problema EELD (MIRJALILI; JANGIR; SAREMI, 2017). Este algoritmo é efetivamente empregado para resolver vários tipos de funções de teste (não modais, multimodais e compostas). As capacidades ALO estão convergindo para a solução geral a uma taxa de convergência rápida devido ao uso do método de seleção de roleta, que também lida com problemas de otimização contínua e discreta.

Comparar ALO com diferentes problemas e aplicações valida sua técnica com melhor desempenho em comparação com outros algoritmos de otimização como GA, PSO, AS, ABC, TSA e HSA.

ALO simula as interações entre formigas e formigas na armadilha, onde são mais eficientes. De acordo com o movimento indeterminado das formigas na selva durante a busca por alimento, um caminho aleatório é escolhido. Para modelar o movimento das formigas, utiliza-se o seguinte modelo matemático descrito na Eq. (4.1) (MIRJALILI, 2015):

$$X(t) = [0, \text{cumsum}(2r(t_1) - 1), \text{cumsum}(2r(t_2) - 1), \dots, \text{cumsum}(2r(t_n) - 1)] \quad (4.1)$$

Onde cumsum calcula o total acumulado, n é a quantidade máxima de iterações, t mostra a iteração atual e $r(t_n)$ é a função estocástica descrita na Eq. (4.2) (TRIVEDI; JANGIR; PARMAR, 2016; YAO; WANG, 2017):

$$r(t) = \begin{cases} 1 & \text{if } rand > 0.5 \\ 0 & \text{if otherwise} \end{cases} \quad (4.2)$$

Onde t exibe a iteração aleatória atual e $rand$ é um número aleatório gerado com distribuição uniforme na faixa de (0,1).

Para preservar a iteração aleatória dentro do intervalo de pesquisa e impedir que as formigas cruzem o caminho, deve-se normalizar de acordo com a Eq. (4.3) (MIRJALILI; JANGIR; SAREMI, 2017):

$$X_i^t = \frac{(x_i^t - a_i) \times (d_i^t - c_i^t)}{b_i - a_i} + c_i^t \quad (4.3)$$

Onde a_i e b_i é o mínimo e máximo das iterações aleatórias i^{th} com a variável, c_i^t e d_i^t indica o mínimo e o máximo i com a iteração na variável t .

Para descrever a captura de formigas, são usados as Eq. (4.4) e (4.5) (RAJU; SAIKIA; SINHA, 2016):

$$c_m^t = Ant - lion_n^t - c^t \quad (4.4)$$

$$d_m^t = Ant - lion_n^t - d^t \quad (4.5)$$

O mais adequado é a construção da armadilha, visto que se utiliza o método da roleta.

Para modelar matematicamente esta hipótese, são propostas as Eq. (4.6) e (4.7) (RAJU; SAIKIA; SINHA, 2016):

$$c^t = \frac{c^t}{I} \quad (4.6)$$

$$d^t = \frac{d^t}{I} \quad (4.7)$$

Onde, c^t é o mínimo de todas as variáveis na t -ésima iteração e d^t indica o vetor incluindo o máximo de todas as variáveis na t -ésima iteração e I é uma razão, descritas em Eq. (4.8).

$$I = 10^w(t/S) \quad (4.8)$$

Onde, t é a iteração atual, S é o número máximo de iterações e w é uma constante cujo valor é dado na Eq. (4.9) (RAJU; SAIKIA; SINHA, 2016):

$$w = \begin{cases} 2 & \text{if } t > 0.1S \\ 3 & \text{if } t > 0.5S \\ 4 & \text{if } t > 0.75S \\ 5 & \text{if } t > 0.9S \\ 6 & \text{if } t > 0.9S \end{cases} \quad (4.9)$$

Capturar formigas por formigas e reconstruir sua armadilha pode ser descrito na Eq.(4.10) (KAMBOJ; BHADORIA; BATH, 2017b):

$$Antlion_j^t = Ant_i^t, \text{ iff } (Ant_i^t) > f(Antlion_j^t) \quad (4.10)$$

No que $Antlion_j^t$ indica a posição j -ésima para antlion selecionada na iteração, Ant_i^t exibe a posição da formiga na iteração e t mostra a iteração atual.

Portanto, assume-se que todas as formigas andam aleatoriamente em torno de um formiga leão selecionado pela roleta e elitismo simultaneamente, conforme a Eq.(4.11) (TRIVEDI; JANGIR; PARMAR, 2016):

$$Ant_i^t = \frac{R_A^t + R_E^t}{2} \quad (4.11)$$

Onde R_A^t é a trajetória aleatória em torno do antlion selecionado pelo método da roleta em t th, R_E^t é a trajetória aleatória em torno do elitismo de t th e Ant_i^t indica a posição i -ésima formiga na iteração t .

4.2 Algoritmo de Otimização Dragonfly Algorithm

O Algoritmo da libélula do inglês *Dragonfly Algorithm* (DA) é um algoritmo de otimização metaheurística inspirado na natureza usado para resolver uma grande variedade de problemas de otimização, baseado em população recentemente bem estabelecido proposto por Mirjalili em 2016. As libélulas são consideradas pequenos predadores carnívoros que caçam e comem quase todos os outros pequenos insetos da natureza. Existem 3.000 espécies diferentes de libélulas, e seu ciclo de vida inclui dois estágios chamados ninfa e adulto (JAFARI; BAYATI CHALESHTARI, 2017), outro fato interessante sobre as libélulas é seu comportamento de

enxame único e raro. As libélulas fervilham com apenas dois propósitos: caça e migração (MIRJALILI, 2016).

O DA foi desenvolvido com base nas estratégias de caça e migração de libélulas. A técnica de caça é conhecida como enxame estático (alimentação), em que todos os membros de um enxame podem voar em pequenos grupos sobre um espaço limitado para descobrir fontes de alimento. A estratégia de migração das libélulas é chamada de enxame dinâmico (migratório). Nesta fase, as libélulas estão dispostas a voar em grupos maiores e, como resultado, o enxame pode migrar. Da mesma forma que outros métodos baseados em enxame, os operadores de DA realizam dois conceitos principais: diversificação, motivada pelas atividades de enxameação estática, e intensificação, estimulada pelas atividades de enxame dinâmico (MIRJALILI, 2016; RAHMAN; RASHID, 2019).

Esse algoritmo pode ser considerado uma técnica de inteligência de enxame para estimar o ótimo global de um determinado problema de otimização. A principal inspiração do algoritmo DA origina-se dos comportamentos de enxameação estática e dinâmica. Esses dois comportamentos de enxameação são muito semelhantes às duas fases principais de otimização usando metaheurísticas: exploração e aproveitamento. As libélulas criam sub-enxames e voam sobre diferentes áreas em um enxame estático, que é o objetivo principal da fase de exploração. No enxame estático, entretanto, as libélulas voam em enxames maiores e ao longo de uma direção, o que é favorável na fase de exploração (MAFARJA et al., 2020).

De acordo com Reynolds, o comportamento dos enxames segue cinco princípios primitivos (REYNOLDS, 1987): Ver Figura 11.

- Separação, que se refere à prevenção de colisão estática dos indivíduos de outros indivíduos na vizinhança. Este procedimento é descrito na Eq. (4.12):

$$S_i = - \sum_{j=1}^N X - X_i \quad (4.12)$$

Onde X é a posição do indivíduo atual, X_j mostra a posição j -ésimo indivíduo vizinho e N é o número de indivíduos vizinhos.

- Alinhamento, que indica a correspondência de velocidade dos indivíduos com a de outros indivíduos da vizinhança. Este conceito é modelado na Eq. (4.13):

$$A_i = \frac{\sum_{j=1}^N V_j}{N} - X \quad (4.13)$$

Onde V_j indica o vetor velocidade do j-ésimo vizinho

- Coesão, que se refere à tendência dos indivíduos para se moverem na direção do centro de massa do próximo. Este conceito é formulado na Eq. (4.14):

$$C_i = \frac{\sum_{j=1}^N x_j}{N} - X \quad (4.14)$$

Onde X é a posição do indivíduo atual, N é o número do próximo e x_j mostra a posição j-ésimo indivíduo vizinho.

- Atração por uma fonte de alimento é calculada da seguinte forma:

$$F_i = X^+ - X \quad (4.15)$$

Onde X é a posição do indivíduo atual e X^+ mostra a posição da fonte de alimento.

- Distração para manter distância de um inimigo é calculada da seguinte forma:

$$E_i = X^- + X \quad (4.16)$$

Onde X é a posição do indivíduo atual e X^- mostra a posição do inimigo.

O comportamento das libélulas é assumido como sendo a combinação desses cinco padrões. Para atualizar a posição de libélulas artificiais em um espaço de busca e simular seus movimentos, dois vetores são considerados: passo (ΔX) e posição (X). O vetor passo é análogo ao vetor velocidade no PSO, e o algoritmo DA é desenvolvido com base no framework do algoritmo PSO. O vetor de passo mostra a direção do movimento das libélulas e é definido da seguinte forma (observe que o modelo de atualização de posição das libélulas artificiais é definido em uma dimensão, mas o método introduzido pode ser estendido para dimensões superiores):

$$\Delta X_{t+1} = (sS_i + aA_i + cC_i + fF_i + eE_i) + w\Delta X_t \quad (4.17)$$

Onde s mostra o peso de separação, S_i indica a separação do i -ésimo indivíduo, a é o peso de alimento, A_i é o alimento do i -ésimo indivíduo, c indica o peso de coesão, C_i é a coesão do i -ésimo indivíduo, f é o fator alimentar, F_i é a fonte de alimento do i -ésimo indivíduo, e é o fator inimigo, E_i é a posição do inimigo do i -ésimo indivíduo, w é o peso de inércia e t é o contador de iteração.

Depois de calcular o vetor de passo, os vetores de posição são calculados da seguinte forma:

$$X_{t+1} = X_t + \Delta X_{t+1} \quad (4.18)$$

Onde t é a iteração atual.

Com separação, alinhamento, coesão, alimento e inimigos fatores (s, a, c, f, e), diferentes comportamentos exploratórios e exploradores podem ser alcançados durante a otimização. Vizinhos de libélulas são muito importantes, então uma vizinhança (círculo em um espaço 2D, esfera em um espaço 3D ou hiper esfera em um espaço nD) com um certo raio é assumida em torno de cada libélula artificial.

As libélulas mostram apenas dois tipos de enxames: estático e dinâmico. As libélulas tendem a alinhar seus voos, mantendo separação e coesão adequadas em um enxame dinâmico. Em um enxame estático, no entanto, os alinhamentos são muito baixos, enquanto a coesão é alta para atacar as presas. Portanto, atribuímos libélulas com alto alinhamento e baixo peso de coesão ao explorar o espaço de busca e baixo alinhamento e alta coesão aos exploradores o espaço de busca. Para transição entre exploração e exploradores, os raios das vizinhanças são aumentados proporcionalmente ao número de iterações. Outra maneira de equilibrar a exploração e os exploradores é ajustar de forma adaptativa os fatores de enxame (s, a, c, f, e, w) durante a otimização.

As libélulas são obrigadas a mudar seus pesos de forma adaptativa para transitar da exploração para exploradores do espaço de busca. Supõe-se também que as libélulas tendem a ver mais libélulas para ajustar a trajetória de voo à medida que o processo de otimização avança. Em outras palavras, a área de vizinhança também é aumentada, pelo que o enxame se torna um grupo no estágio final de otimização para convergir para o ótimo global. A fonte de alimento e o inimigo são escolhidos entre as melhores e piores soluções que todo o enxame encontra até agora. Isso causa convergência para áreas promissoras do espaço de busca e divergência para regiões não promissoras do espaço de busca.

Para melhorar a aleatoriedade, o comportamento estocástico e a exploração das libélulas artificiais, elas são obrigadas a voar ao redor do espaço de busca usando um passeio aleatório

(voo de Lévy) quando não há soluções vizinhas. Nesse caso, a posição das libélulas é atualizada usando a seguinte equação:

$$X_{t+1} = X_t + Lévy(d) \times X_t \quad (4.19)$$

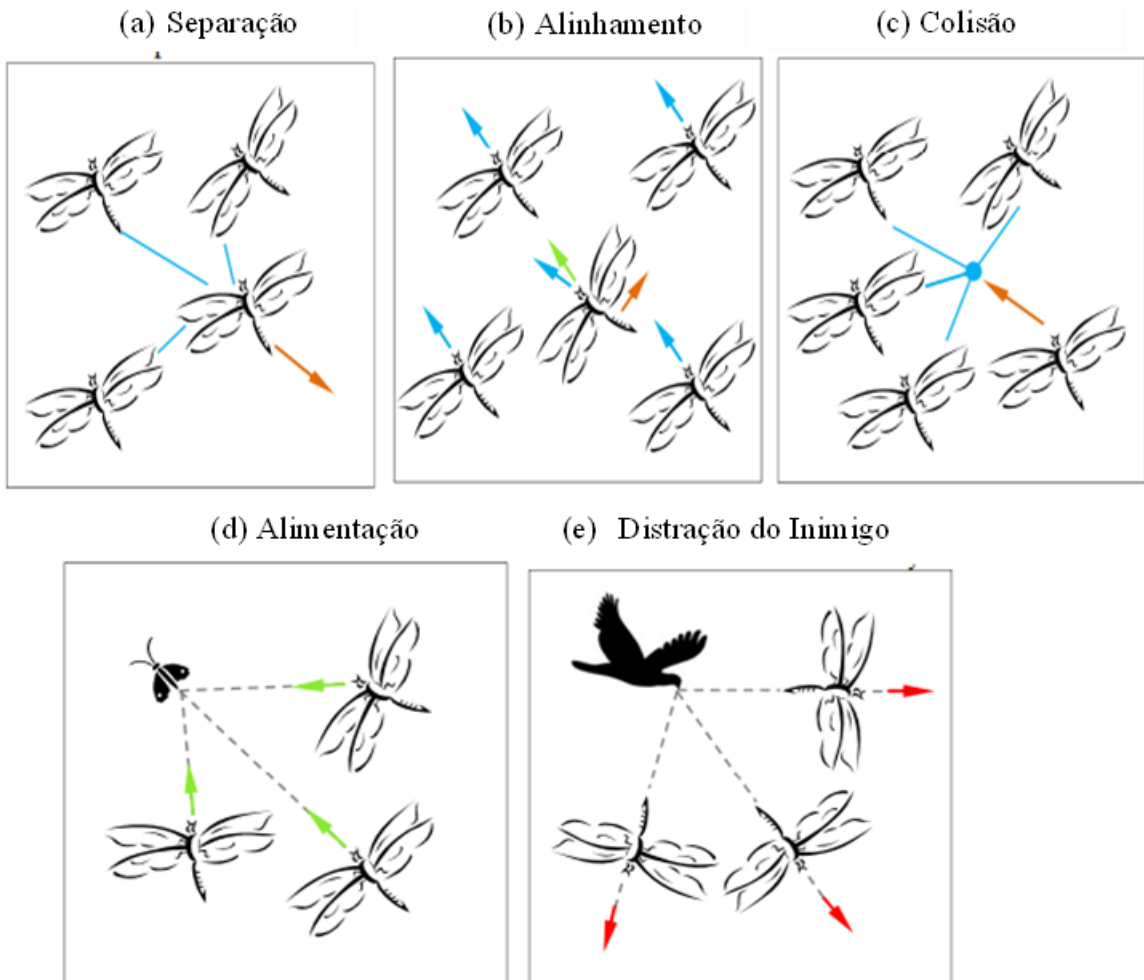
onde t é a iteração atual e d é a dimensão dos vetores de posição.

O voo Lévy é calculado da seguinte forma [35]:

$$Lévy(x) = 0.01 \times \frac{r_1 \times \sigma}{|r_2|^{\frac{1}{\beta}}} \quad (4.20)$$

onde r_1, r_2 são dois números aleatórios em $[0,1]$, β é uma constante

Figura 11- Comportamento Natural das Libélulas



Fonte: (MIRJALILI, 2016)

4.3 Algoritmo Differential Evolution

O algoritmo *Differential Evolution* (DE) foi criado para ser um algoritmo de otimização heurística em problemas de otimização numérica (STORN; PRICE, 1997).

O algoritmo DE é excepcionalmente simples, significativamente mais rápido e robusto. A ideia principal do DE é adaptar a pesquisa durante o processo evolutivo. No início do incremento, as perturbações são grandes, visto que as populações parentais estão distantes umas das outras. Conforme o processo evolutivo amadurece, a população converge para uma pequena região e as perturbações tornam-se adaptativamente pequenas (BASU, 2016; OPARA; ARABAS, 2019; STORN; PRICE, 1997).

O DE, realiza uma pesquisa exploratória global durante os estágios iniciais do processo evolutivo, e a exploração local à medida que o processo evolutivo amadurece. No DE o mais apto de um descendente compete um a um com o do pai correspondente, resultando em uma taxa de convergência mais rápida, o que o torna diferente de outros algoritmos evolutivos. O DE usa os operadores aritméticos para evoluir a partir de uma população inicial gerada aleatoriamente até uma solução final. Basicamente, a diferença ponderada entre dois indivíduos é adicionada a um terceiro indivíduo na população. Desta forma, nenhuma distribuição separada de probabilidade tem de ser usada, o que faz com que o esquema seja completamente auto organizado. Assim, o DE é um procedimento de exploração estocástica que imita os algoritmos evolutivos. Inicialização, mutação, cruzamento e seleção são os processos envolvidos no DE (MARIKUTTIKAN et al., 2021; WU; ZHAO; LIU, 2017).

O algoritmo DE usa a diferença entre os indivíduos para guiar esse algoritmo na busca no espaço de soluções. Inclui principalmente população de inicialização, operação de mutação, operação de cruzamento, operação de seleção e assim por diante. A ideia principal do DE é diferenciar e dimensionar entre dois vetores individuais diferentes na mesma população, e adicionar um terceiro vetor individual nesta população para obter um vetor individual de mutação, cruzado com o vetor individual pai com certa probabilidade de gerar um terceiro vetor individual. Finalmente, o terceiro vetor individual e o vetor individual pai são executados em seleção gulosa, e o melhor vetor individual é salvo para a próxima geração. Os processos básicos de evolução do DE são descritos a seguir (DENG et al., 2021).

4.3.1 Operação de Inicialização

O algoritmo DE usa vetores D-dimensionais (M) como valor inicial. Define o número da população (N), cada indivíduo pode ser expresso como $x_i(G) =$

$(x_{i1}(G), x_{i2}(G), \dots, x_{iD}(G))$. A população inicial é gerada em $[x_{min}, x_{max}]$. Onde, M é o número de vetores de dimensão D , N é o número de populações e $x_i(G)$ é o i -ésimo indivíduo (DENG et al., 2021; ZHAN et al., 2020).

$$x_{iD} = x_{min} + rand(0,1) * (x_{max} + x_{min}) \quad (4.21)$$

onde G representa a G -ésima geração, x_{max} representa o valor máximo do espaço de busca, x_{min} representa o valor mínimo do espaço de busca, $rand(0,1)$ representa um número aleatório que atende a uma distribuição normal entre $(0,1)$.

4.3.2 Operação de Mutação

O algoritmo DE usa a operação de mutação para gerar um vetor de mutação $V_{i,G}$ para cada indivíduo $x_{i,G}$ na população atual (vetor alvo). Para cada vetor alvo gerado, um vetor de mutação correspondente pode ser gerado por uma determinada estratégia de mutação. De acordo com os diferentes métodos de geração de indivíduos mutantes, várias estratégias de mutação para o DE são formadas. As cinco estratégias de mutação mais comumente usadas são descritas a seguir (DENG et al., 2021).

$$1) \text{ DE/rand/1 } V_{i,G} = x_{r1,G} + F \cdot (x_{r2,G} - x_{r3,G}) \quad (4.22)$$

$$2) \text{ DE/best/1 } V_{i,G} = x_{best,G} + F \cdot (x_{r1,G} - x_{r2,G}) \quad (4.23)$$

$$3) \text{ DE/rand - to - best/1 } V_{i,G} = x_{i,G} + F \cdot (x_{best,G} - x_{i,G}) + F \cdot (x_{r1,G} - x_{r2,G}) \quad (4.24)$$

$$4) \text{ DE/best/2 } V_{i,G} = x_{i,G} + F \cdot (x_{best,G} - x_{i,G}) + F \cdot (x_{r1,G} - x_{r2,G}) \quad (4.25)$$

$$5) \text{ DE/rand/2 } V_{i,G} = x_{r1,G} + F \cdot (x_{r2,G} - x_{r3,G}) + F \cdot (x_{r4,G} - x_{r5,G}) \quad (4.26)$$

onde $r_1; r_2; r_3; r_4$ e r_5 são números inteiros exclusivos gerados aleatoriamente dentro de $[1, M]$. O fator de escala F é um parâmetro de controle positivo para escalar o vetor de diferença. $x_{best,G}$ é o melhor vetor individual com melhor valor de fitness na G -ésima geração.

4.3.3 Operação de Cruzamento

Cada par de vetores alvo $x_{i,G}$ e seus vetores de mutação correspondentes $V_{i,G}$ são cruzados para gerar um vetor de teste $U_{i,G} = (u_{1,G}, u_{2,G}, \dots, u_{i,G})$. No algoritmo DE, um cruzamento binomial é definido como segue.

$$u_{i,G} = \begin{cases} v_{i,G} & \text{if } (rand_j(0,1) \leq CR) \text{ or } (j = j_{rand}, j = 1, 2, 3, \dots, D) \\ x_{i,G} & \text{otherwise} \end{cases} \quad (4.27)$$

onde a taxa de cruzamento CR é uma constante especificada em $[0,1]$, que é usada para controlar a proporção duplicada do vetor de mutação. j_{rand} é um inteiro selecionado aleatoriamente em $[1, D]$.

4.3.4 Operação de Seleção

Se os valores dos parâmetros excederem os limites superiores ou inferiores correspondentes, eles podem ser reinicializados aleatoriamente e uniformemente dentro do intervalo determinado. Em seguida, os valores da função objetivo de todos os vetores de teste são avaliados e a operação de seleção é realizada. O valor da função objetivo $f(U_{i,G})$ de cada vetor de teste é comparado com o valor da função objetivo do vetor alvo correspondente na população atual. Se o valor da função objetivo do vetor de teste for menor ou igual ao do vetor alvo correspondente, então o vetor alvo é substituído pelo vetor de teste para a próxima geração. Caso contrário, o vetor alvo permanece para a próxima geração. A operação de seleção pode ser expressa da seguinte forma (DENG et al., 2021; ZHAN et al., 2020).

$$X_{i,G+1} = \begin{cases} U_{i,G} & \text{If } (f(U_{i,G}) \leq f(X_{i,G})) \\ X_{i,G} & \text{otherwise} \end{cases} \quad (4.28)$$

4.4 Considerações Finais do Capítulo IV

Neste capítulo foram descritos os conceitos e definições relacionadas as técnicas de otimização metaheurísticas *Ant Lion Optimizer (ALO)*, *DragonFly Algorithm (DA)* e *Differential Evolution (DE)*. No próximo capítulo, descrevem-se detalhadamente os procedimentos computacionais usados nesta tese. Os algoritmos durante sua implementação no MATLAB foram implementados para evitar ficar preso num mínimo local, fazer uma comparação entre as potências dos motores para identificar os motores menos eficientes e com o auxílio da produção de energia gerada pelas usinas solares busca-se o desligamento dos motores menos eficientes.

CAPÍTULO V

5 PROPOSTA DA TESE E METODOLOGIA

Uso de técnicas de otimização metaheurísticas aplicadas ao despacho econômico e ambiental de usinas termoeletricas e fotovoltaicas.

5.1 Resolvendo o Problema DEA com Ant Lion Optimizer (ALO)

As etapas para um aplicativo de otimização ALO são as seguintes:

- **Etapa 1.** O conjunto de formigas é inicializado com valores aleatórios e são os principais agentes de pesquisa em ALO.
- **Etapa 2.** O valor de aptidão de cada formiga é avaliado usando uma função objetivo (Eq. 3.14) em cada iteração.
- **Etapa 3.** As formigas se movem pelo espaço de pesquisa usando passeios aleatórios pelas formigas.
- **Etapa 4.** A posição das formigas é avaliada a cada iteração e realocando as que estão em melhor posição.
- **Etapa 5.** Há uma formiga leão atribuído a cada formiga e atualiza sua posição se a formiga ficar mais preparada.
- **Etapa 6.** Também existe uma formiga leão de elite que afeta o movimento das formigas, independentemente da distância.
- **Etapa 7.** Se uma formiga leão se tornar melhor do que a elite, ele será substituído pela elite.
- **Etapa 8.** As etapas 2 a 7 são executadas repetidamente até que um critério final seja satisfeito.
- **Etapa 9.** A posição e o valor de aptidão da formiga leão de elite são retornados como a melhor estimativa para a otimização geral.

A trajetória aleatória de formigas usando na Eq. (4.1). Além das formigas, supomos que as formigas leão, também estejam escondidas em algum lugar do espaço de busca, para salvar suas posições e valores de aptidão, utiliza-se a seguinte matriz (5.1, 5.3, 5.4 e 5.5) (TRIVEDI; JANGIR; PARMAR, 2016):

$$M_{Ant} = \begin{bmatrix} Ant_{1,1} & Ant_{1,2} & Ant_{1,3} & \dots & Ant_{1,d} \\ Ant_{2,1} & Ant_{2,2} & Ant_{2,3} & \dots & Ant_{2,d} \\ \dots & \dots & \dots & \dots & \dots \\ Ant_{n,1} & \dots & \dots & \dots & Ant_{n,d} \end{bmatrix}_{n \times d} \quad (5.1)$$

Onde M_{Ant} é a matriz que armazena a posição de cada formiga leão, AL_{ij} exibe o valor da j -ésima dimensão da formiga leão i , n é o número de formigas leão e d é o número de variáveis.

Para avaliar cada formiga (ou seja, unidades geradoras), as seguintes funções objetivo, descritas em (29) e (30), são usadas durante a otimização e a matriz (5.2) armazena o valor dos atributos de todas as formigas:

$$M_{OA} = \begin{bmatrix} f([Ant_{1,1}, Ant_{1,2}, \dots, Ant_{1,d}]) \\ f([Ant_{2,1}, Ant_{2,2}, \dots, Ant_{2,d}]) \\ \vdots \\ f([Ant_{n,1}, Ant_{n,2}, \dots, Ant_{n,d}]) \end{bmatrix} \quad (5.2)$$

Onde M_{OA} é a matriz que armazena a adequação de cada formiga, Ant_{ij} exibe o valor da j ésimas dimensão de i -ésima, n é o número de formigas e f é a função objetivo.

Para otimizar custos e geração de energia foi utilizado as Eq. (5.3) e (5.4):

$$M_{AL} = \begin{bmatrix} AL_{1,1} & AL_{1,2} & AL_{1,3} & \dots & AL_{1,d} \\ AL_{2,1} & AL_{2,2} & AL_{2,3} & \dots & AL_{2,d} \\ \dots & \dots & \dots & \dots & \dots \\ AL_{n,1} & \dots & \dots & \dots & AL_{n,d} \end{bmatrix}_{n \times d} \quad (5.3)$$

Onde M_{AL} armazena a posição de cada formiga, AL_{ij} exibe ALO e o valor da dimensão j , n é o número de formigas e d é o número de variáveis (geradores).

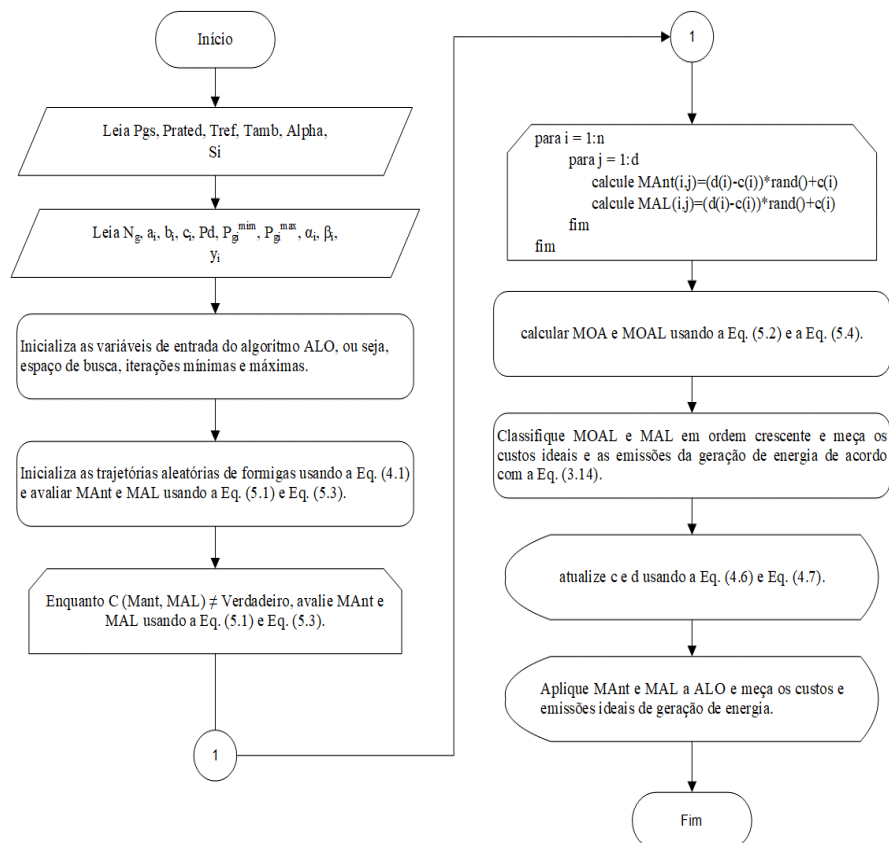
$$M_{OAL} = \begin{bmatrix} f([AL_{1,1}, AL_{1,2}, \dots, AL_{1,d}]) \\ f([AL_{2,1}, AL_{2,2}, \dots, AL_{2,d}]) \\ \vdots \\ f([AL_{n,1}, AL_{n,2}, \dots, AL_{n,d}]) \end{bmatrix} \quad (5.4)$$

Onde M_{OAL} armazena os atributos de cada ALO, AL_{ij} mostra o valor da j -ésima dimensão de j -ésima ALO, n é o número de formigas e f é a função objetivo de otimização.

A solução apresentada envolve o número de gerações do sistema que será otimizado, resultando na minimização dos custos e das emissões dos gases poluentes, conforme apresentado por (3.9), e atendendo às restrições de (3.2-3.7).

A equação (3.9) é aplicada para avaliar o desempenho do DEA, embora os custos e as emissões ideais sejam alcançados. Para restrições de desigualdade análogas a outras técnicas, quando as soluções alcançadas para qualquer iteração estão fora dos limites, ALO indica os valores de limite, enquanto para restrições de igualdade, quando violado, o fator de penalidade é implementado e incorporado à função. De acordo com (TRIVEDI; JANGIR; PARMAR, 2016). O algoritmo continuará até que a iteração máxima e os melhores resultados sejam encontrados. O fluxograma do método ALO é mostrado na Figura 12.

Figura 12 - Fluxograma do ALO para problema do despacho econômica ambiental.



Fonte: O Autor, (2022).

5.2 Resolvendo o Problema DEA com Dragonfly Algorithm (DA)

As etapas para um aplicativo de otimização DA são as seguintes:

- **Etapa 1.** Escolha o número de gerador, e inicialize a matriz populacional de libélulas de variável determinística e irradiância solar aleatoriamente;

- **Etapa 2.** Inicialize os vetores de passo ΔX ;
- **Etapa 3.** Verifique os limites de restrição usados neste problema usando as Eqs. (3.9) e (3.13);
- **Etapa 4.** Avalie a função de aptidão e calcule a média e o desvio padrão de cada libélula;
- **Etapa 5.** Atualize o inimigo e o recurso alimentar usando as Eqs. (4.16) e (4.15);
- **Etapa 6.** Atualize o vetor de velocidade usando a Eq. (4.17);
- **Etapa 7.** Calcule S, A, C, F, E usando as Eqs. (4.12) a (4.16);
- **Etapa 8.** Atualize os raios vizinhos;
- **Etapa 9.** Se pelo menos uma libélula vizinha estiver presente para cada indivíduo, vá para a etapa 11; caso contrário, vá para a etapa 12;
- **Etapa 10.** Atualize o vetor de posição e velocidade usando as Eqs. (4.17) e (4.18);
- **Etapa 11.** Verifique o limite do gerador usando as Eqs. (3.10) e (3.13);
- **Etapa 12.** Avalie a função de aptidão e calcule a média e o desvio padrão usando a libélula atualizada e determine o valor de aptidão (melhor valor médio) para a mesma. Melhor aptidão é o melhor valor médio dos valores da função de aptidão avaliados para cada conjunto de soluções, usando a Eq. (4.19);
- **Etapa 13.** Vá para a etapa 7 e repita o processo até atingir o critério de término.

O método DA proposto consegue resolver de forma robusta o problema de otimização não convexos e de grande escala. Assim, foi aplicado de forma eficiente para o problema de DEA (DAS; BHATTACHARYA; RAY, 2020; MIRJALILI, 2016; SURESH; SREEJITH, 2017). O pseudocódigo do algoritmo DA é mostrado logo abaixo. As etapas usadas para resolver o problema do DEA são mostrados no fluxograma na Figura 13.

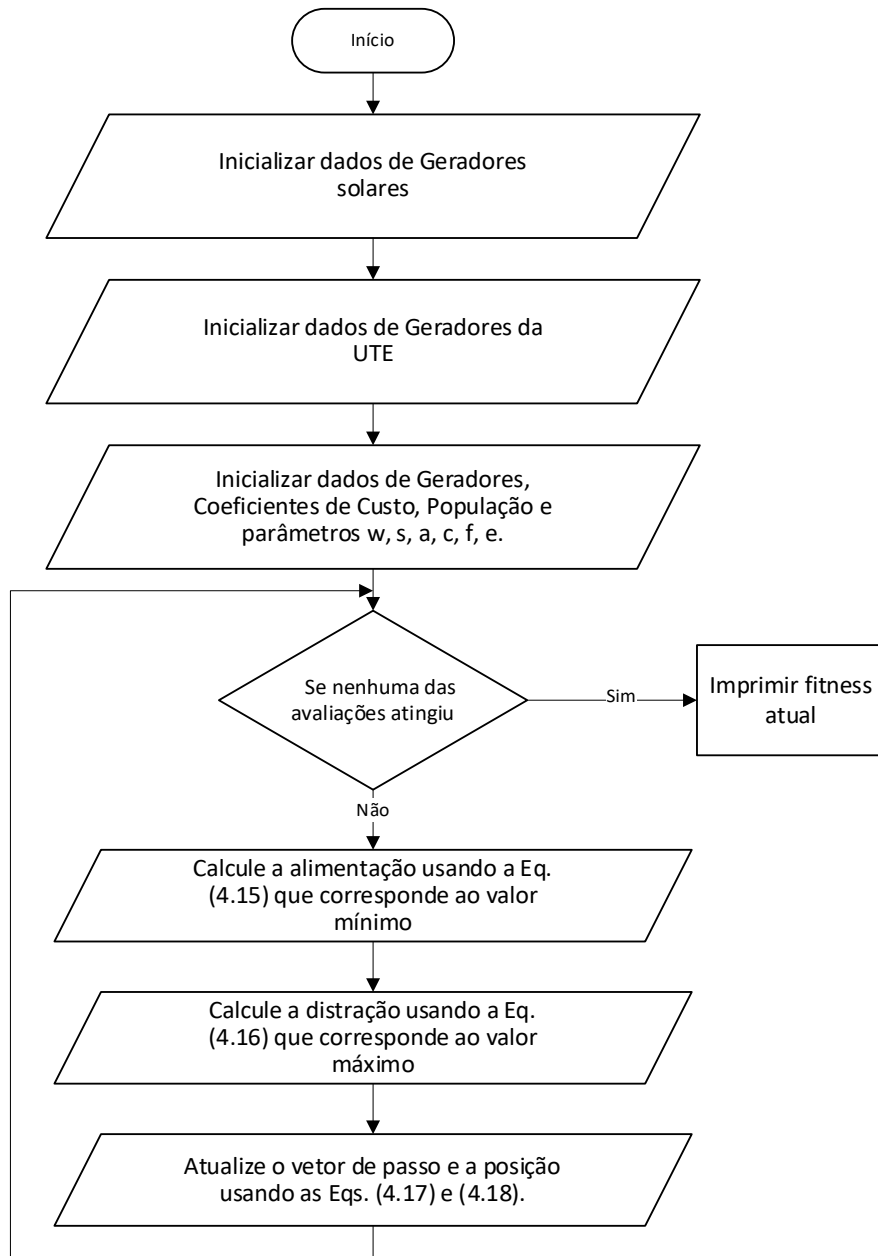
Figura 13 - O pseudocódigo do algoritmo DA, adaptado de (MIRJALILI, 2016).

```

Inicialize a população de libélulas  $X_i$  ( $i = 1, 2, \dots, n$ )
Inicialize os vetores de passo  $\Delta X_i$  ( $i = 1, 2, \dots, n$ )
enquanto a condição final não for satisfeita
    Calcular os valores objetivos de todas as libélulas
    Atualizar a fonte de alimento e o inimigo
    Atualize w, s, a, c, f, e
    Calcule S, A, C, F, E usando as Eqs. (4.12) a (4.16)
    Atualize o raio vizinho
    se uma libélula tiver pelo menos uma libélula vizinha
        Atualize o vetor de velocidade usando a Eq. (4.17)
        Atualize o vetor de posição usando a Eq. (4.18)
    senão
        Atualize o vetor de posição usando a Eq. (4.19)
    fim se
    Verifique e corrija as novas posições com base nos limites das variáveis
Fim enquanto

```


Figura 14 - Fluxograma do DA para problema do despacho econômica ambiental.



Fonte: Adaptado de (SURESH; SREEJITH, 2017).

A UTE selecionado para a simulação é composto por seis (06) unidades geradoras, apresenta coeficientes de custo de combustível (a, b, c) e limites de potência mínimo (Pmin) e máximo (Pmax). Os dados do sistema de teste são obtidos conforme mostrado na Tabela 9 (KHAN et al., 2015a).

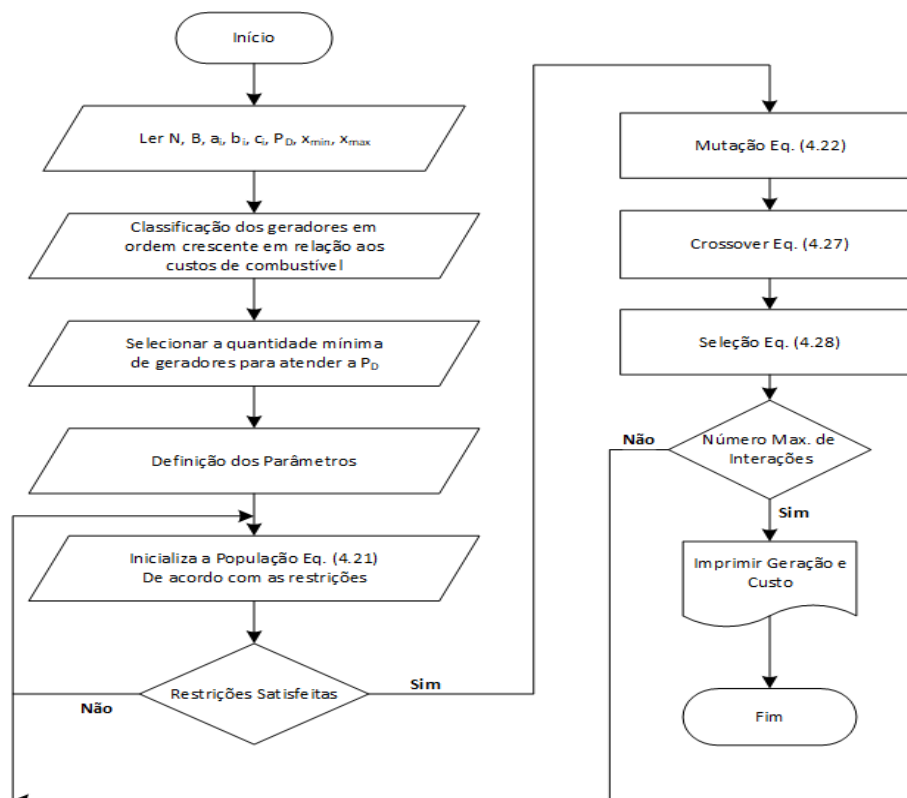
5.3 Resolvendo o Problema DEA com Differential Evolution (DE)

As etapas para o procedimento do algoritmo de otimização DE são as seguintes:

- **Etapa 1:** Inicializar o carregamento dos dados das usinas (dados dos geradores obtidos na Tabelas 09), o total de demanda de potência ativa a ser fornecido pela usina térmica é solar em MW.
- **Etapa 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.
- **Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa P_D ;
- **Passo 4:** Definir os parâmetros do algoritmo:
 - População: 300;
 - Iterações: 1500;
- **Passo 5:** Serão executadas as Eqs. (4.21, 4.22, 4.27, 4.28). Além disso, os parâmetros de controle dos indivíduos com falha são regenerados aleatoriamente na faixa de seus limites.
- **Passo 6:** Se o processo de evolução chegar ao número máximo de iteração, a evolução será interrompida. Caso contrário, o processo vai para a Etapa 2.

As etapas usadas para resolver o problema do DEA são mostrados no fluxograma na Figura 15.

Figura 15 - Fluxograma do DE para problema do despacho econômica ambiental.



Fonte: Adaptado de (LIN; BIAN; DONG, 2022)

5.4 Estudo de caso: Sistema de Teste de 6 unidades IEEE e 13 Usinas Solares

O modelo proposto considera uma demanda de 100% a ser atendida, e por questões de segurança será utilizada 70% da capacidade do USF, devido à instabilidade da geração do USF, sendo o restante da demanda atendido pela UTE. No percentual a ser atendido pelo UTE, é aplicada a otimização para o problema DEA, considerando um sistema teste com 6 UG para suprir a necessidade da demanda. A UTE selecionado para o estudo de caso, apresenta coeficientes de custo de combustível (a, b, c) e limites de potência mínimo (Pmin) e máximo (Pmax) conforme mostrado na Tabela 9 (KHAN et al., 2015a).

Tabela 9 - Coeficientes de custo de combustível para cada unidade geradora UTE.

Gerador Nº.	a (\$/MW ² h)	b (\$/MW h)	c (\$/h)	Pmin (MW)	Pmax (MW)
1	0,15247	3,853,973	7,567,989	10	125
2	0,10587	4,615,916	4,513,251	10	150
3	0,02803	4,039,655	1,049,325	40	250
4	0,03546	3,830,553	1,243,531	35	210
5	0,02111	3,632,782	1658,57	130	325
6	0,01799	3,827,041	1353,27	125	315

Fonte:(ARUL; RAVI; VELUSAMI, 2014; KHOA et al., 2015; RAJASOMASHEKAR; ARAVINDHABABU, 2012).

A Tabela 10 mostra os coeficientes de emissão das unidades UTE (α , β e γ) (ARUL; RAVI; VELUSAMI, 2014; KHOA et al., 2015; RAJASOMASHEKAR; ARAVINDHABABU, 2012).

Tabela 10 - Coeficientes de emissão das usinas.

Gerador No.	α (kg/MW ² h)	β (kg/MW h)	γ (kg/h)
1	0,00419	0,32767	13,85932
2	0,00419	0,32767	13,85932
3	0,00683	-0,54551	40,2669
4	0,00683	-0,54551	40,2669
5	0,00461	-0,51116	42,89553
6	0,00461	-0,51116	42,89553

Fonte: (ARUL; RAVI; VELUSAMI, 2014; KHOA et al., 2015; RAJASOMASHEKAR; ARAVINDHABABU, 2012).

A Tabela 11 apresenta as classificações de energia e custos unitários de diferentes SPP, aproximados para estarem dentro da faixa fornecida.

Tabela 11 - Classificações de energia e taxas por unidade de USF.

Usina	P_{rated} (Mw)	Valor Unitário (\$/kw h)
1	20	0,22
2	25	0,23
3	25	0,23
4	30	0,24
5	30	0,24
6	35	0,25
7	35	0,26
8	40	0,27
9	40	0,27
10	40	0,28
11	40	0,28
12	40	0,28
13	40	0,28

Fonte: (KHAN; PERVAIZ, 2013).

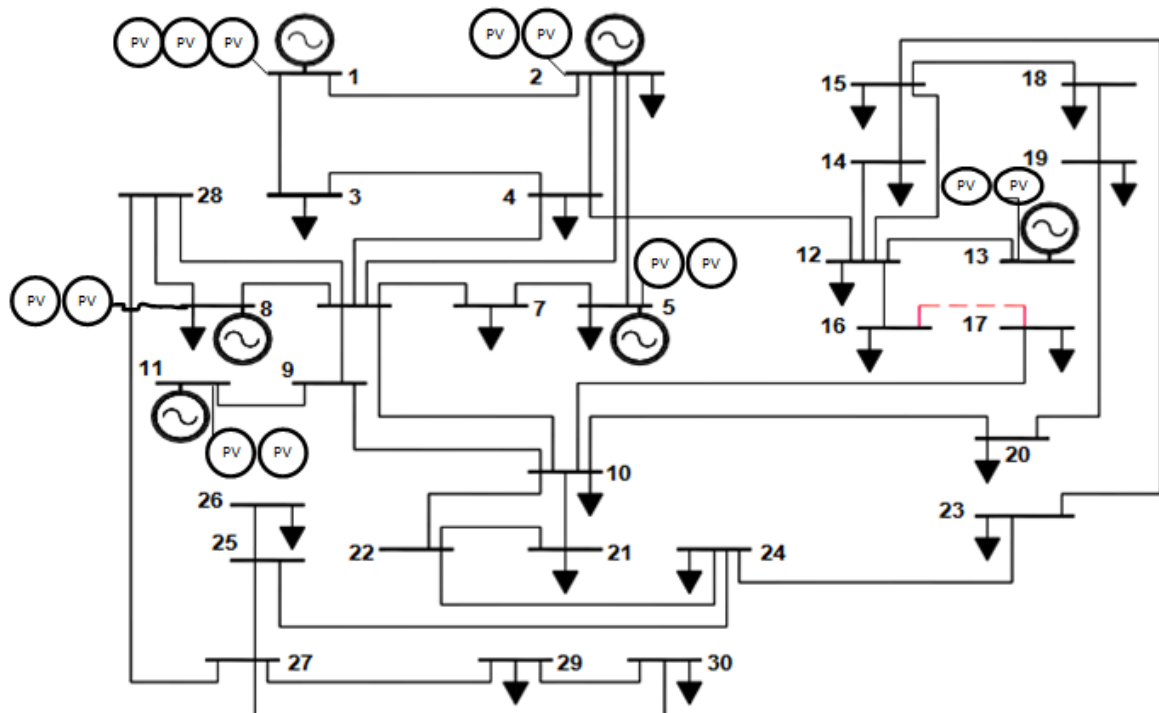
A Tabela 12 abrange a radiação solar global, bem como os perfis de temperatura e carga de Islamabad para o dia 17 de julho de 2012. Os dados globais de radiação solar foram gerados usando o Geospatial Toolkit, os dados relacionados à demanda de energia da região de Islamabad foram retirados do IESCO (KHAN et al., 2015a) e o perfil de temperatura foi obtido de (“Previsão do tempo local, notícias e condições... - Google Acadêmico”, 2021). O dia 17 de julho foi selecionado arbitrariamente a partir dos únicos dados de demanda disponíveis de julho de 2012.

Tabela 12 - Radiação solar, demanda de energia e temperatura.

Hora	Radiação Solar Global (W/m²)	Potência da Demanda (MW)	Temp. (°C)
01:00	0	965	30
02:00	0	1142	29
03:00	0	1177	28
04:00	0	1198	28
05:00	5,4	1153	28
06:00	101	1136	-
07:00	253,7	1138	29
08:00	541,2	1060	31
09:00	530,4	1155	33
10:00	793,9	1244	34
11:00	1078	1088	35
12:00	1125,6	1240	36
13:00	1013,5	1135	37
14:00	848,2	1318	37
15:00	726,7	1074	37
16:00	654	1190	38
17:00	392,9	1276	38
18:00	215,1	1154	37
19:00	38,5	1333	35
20:00	0	1322	34
21:00	0	1269	34
22:00	0	1139	33
23:00	0	1202	32
00:00	0	1291	-

Fonte: (KHAN et al., 2015b).

Figura 16 – Diagrama Unifilar do Sistema de Teste com 6 UG e 13 USF.



Fonte: Adaptado do Diagrama Unifilar do Sistema IEEE com 6 geradores.

5.5 Análise e Discussão dos Resultados

Esta seção mostra os resultados das técnicas metaheurísticas *Ant Lion Optimizer*, *Dragonfly* e *Differential Evolution* propostos, comparando com as simulações obtidas em (KHAN et al., 2015b). Os modelos propostos foram desenvolvidos no ambiente computacional com o software MATLAB. As configurações de controle usadas para as simulações foram: $C1$, $C2 = 2$; $r1$, $r2$ = números aleatórios entre 0 e 1; Número máximo de iterações = 1500 com populações variando entre 100, 200 e 300 indivíduos. Os melhores resultados obtidos pelas técnicas metaheurísticas são apresentados em forma de tabela e gráficos, para a população de 300 indivíduos. A Tabela 13, apresenta os resultados comparativos das técnicas simuladas às 10h00, que buscam atender uma demanda total de 1244MW de potência, incluindo a geração solar fotovoltaica.

Tabela 13 - Resultados obtidos com as técnicas incluindo energia solar para demanda de 1244 MW às 10:00h.

Horário da Demanda: 10h				
Demanda Total do local (MW): 1244				
UG	Khan [8] PSO	ALO	DA	DE
P1 (MW)	120.4479	72.1687841	67.48445355	77.707672
P2 (MW)	92.2947	0.0	0.0	0.0
P3 (MW)	155.8062	192.3938123	174.343078	181.64957
P4 (MW)	76.4153	155.8548152	193.2972563	179.796037
P5 (MW)	257.9089	305.0188986	284.4000136	281.999872
P6 (MW)	302.2846	282.2128469	287.6789041	284.097658
Potência Elétrica (MW)	1005.1576	1007.6492	1007.2037	1005.2508
Potência Energia Solar (MW)	238.825	238.972	238.972	238.972
Potência Total (MW)	1243.9826	1246.6212	1246.1757	1244.2228
Custo de Combustível (\$/h)	52,626.00	50,782.54	50,712.79	50,654.61
Emissões (m3)	880.80	984.83	965.42	935.26
Redução de Emissões (m3/h)	19.20%	19.17%	19.18%	19.21%

Fonte: O Autor, (2022).

Na comparação (Tabela 13), percebe-se que a demanda de 1244 MW necessária para o cronograma é alcançada pelas três técnicas de otimização, e o algoritmo consegue, de forma inteligente, verificar a potência de todos os geradores e ao final fazer o desligamento, ou não, dos geradores menos eficientes para o horário. Conseguindo assim, atender a demanda de forma eficiente, garantido todos os parâmetros operacionais do sistema e reduzindo o consumo de combustível e poluentes na atmosfera. O gerador menos eficiente após as três técnicas simuladas foi o UG P2, seu desligamento não causou perturbações ou instabilidade para a geração da potência, com isso não sofreu grandes variações, proporcionando uma geração de potência ótima para o sistema.

Por outro lado, o gerador P1 apresentou menor potência nas simulações, mas na técnica DE apresenta uma potência com melhor desempenho. Enquanto no gerador P3, as variações de potência foram mais significativas em relação ao gerador P1, quando aplicada as três técnicas. O mesmo ocorrendo para os demais geradores P4, P5 e P6.

Os resultados obtidos com as três técnicas (ALO, DA e DE) em relação à técnica de (KHAN et al., 2015), aplicada às 10h00, obtivemos uma redução média de **3,63%** correspondentes a \$ **1,909.35** no custo do combustível, com o auxílio do uso de energia solar fotovoltaica. A redução média de poluentes na atmosfera foi de aproximadamente **19.18%**. A Figura 17 exhibe a comparação entre potência e emissão por gerador simulado na técnica *Ant Lion Optimizer* outro ponto destacado na Figura 18 que é o custo de combustível por geradores também simulado com a técnica *Ant Lion Optimizer*.

Na Figura 19 é exibida a simulação da técnica *Drangonflay Algorithm* que é a comparação entre potência e emissão apresentando outros resultados para a demanda solicitada, e na Figura 20 exhibe o custo de combustível utilizado por cada gerador simulado na técnica *Drangonflay Algorithm*.

Na Figura 21 usando os mesmos critérios de simulação, é comparado a potência e emissão dos motores utilizando a técnica *Differential Evolution* que entre as outras técnicas apresentadas fornece resultados mais favoráveis para o horário demandado, da mesma forma, a Figura 22 robustece a sistemática do *Differential Evolution* de economia, apresentando resultados mais favoráveis todo esse contexto é apresentado nos resultados dos dados obtidos na Tabela 13, que representam os valores de potência, emissões e custos de combustível gerados pelas técnicas (ALO, DA e DE) às 10:00. Por fim, na Figura 23 é exibido o gráfico de Pareto da técnica DE comparando custo e emissões por ser a técnica que apresentou melhores resultados.

Figura 17 - Comparação entre Potência e Emissões por Geradores.

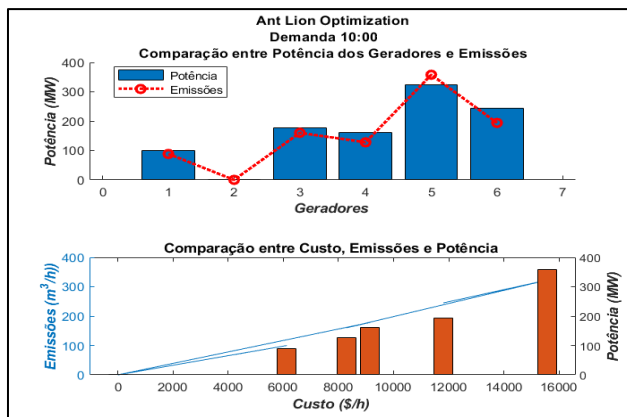


Figura 18 - Custo de Combustível por Geradores.

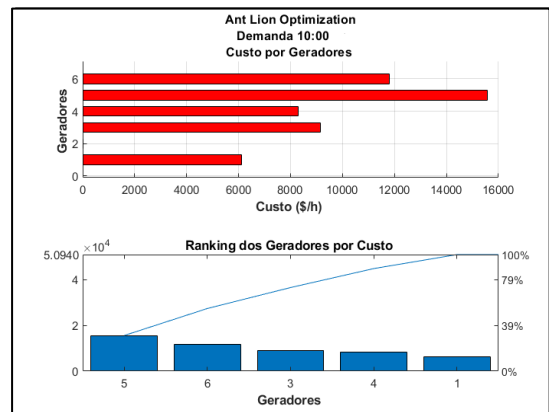


Figura 19 - Comparação entre Potência e Emissões por Geradores.

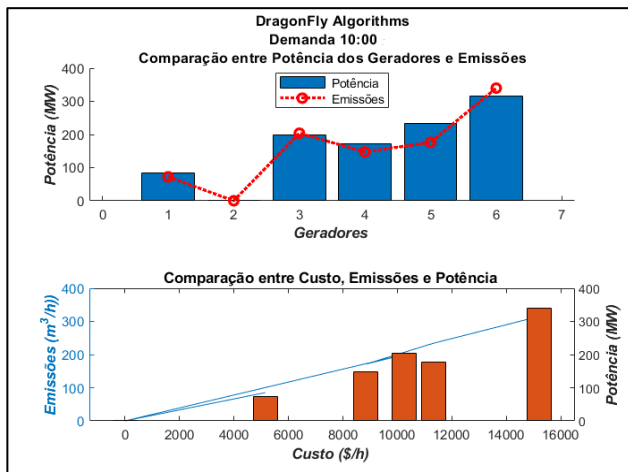


Figura 20 - Custo de Combustível por Geradores.

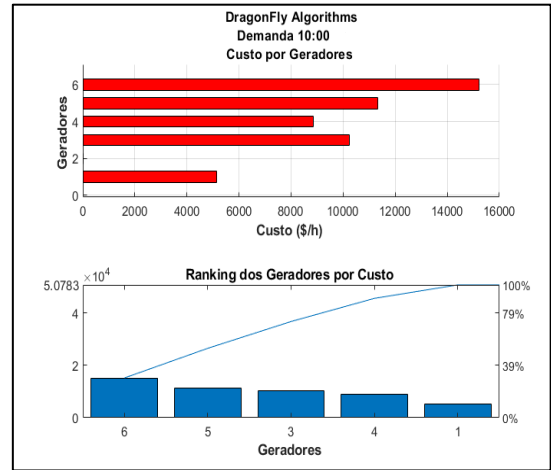


Figura 21 - Comparação entre Potência e Emissões por Geradores.

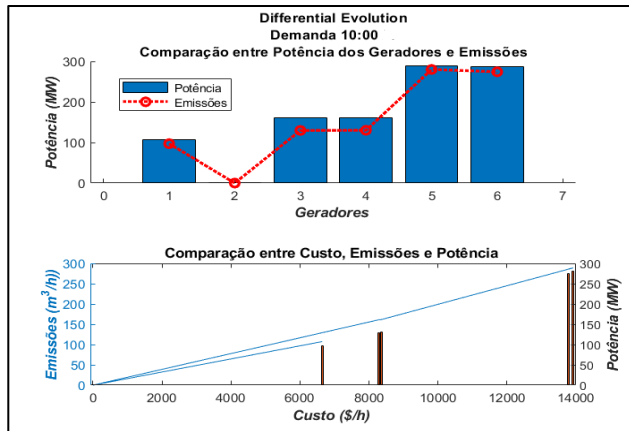


Figura 22 - Custo de Combustível por Geradores.

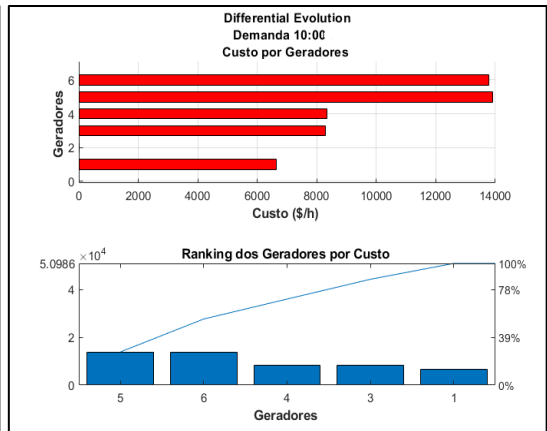
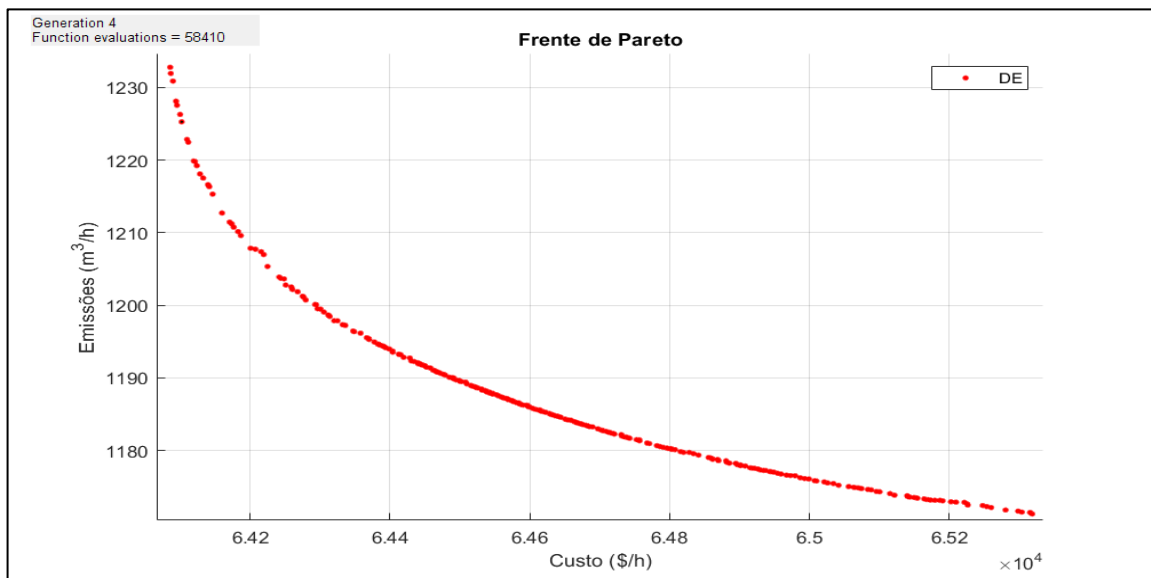


Figura 23 - Frente de Pareto técnica DE simulado às 10:00h



Fonte: O Autor, (2022).

A Tabela 14, apresenta os resultados das simulações comparativas às 11h00, que busca atender a demanda total de 1088 MW de potência, incluindo a geração solar fotovoltaica.

Tabela 14 - Resultados obtidos com as técnicas incluindo energia solar para demanda de 1088 MW às 11: 00h.

Horário da Demanda: 11h				
Demanda Total do local (MW): 1088				
UG	Khan [8] PSO	ALO	DA	DE
P1 (MW)	10.1062	65.7665763	63.5256274	72.8252697
P2 (MW)	10	0.0	0.0	0.0
P3 (MW)	99.1	0.0	0.0	0.0
P4 (MW)	168.682	172.689098	167.869883	170.4202
P5 (MW)	235.8781	263.148118	276.66063	265.257442
P6 (MW)	246.7809	269.235253	261.450333	259.150051
Potência Eletrica (MW)	770.5472	770.8390	769.5065	767.6530
Potência Energia Solar (MW)	317.471	323.1775	323.1775	323.1775
Potência Total (MW)	1088.0182	1094.02	1092.68	1090.83
Custo de Combustível (\$/h)	39,426.00	38,706.90	38,609.38	38,584.03
Emissões (m3)	607.30	699.32	697.22	665.37
Redução de Emissões (m3/h)	29.18%	29.54%	29.58%	29.63%

Fonte: O Autor, (2022).

Ao avaliar a Tabela 14, percebe-se que a demanda de 1088 MW necessária para o cronograma é alcançada pelas três técnicas de otimização, e o algoritmo consegue de forma inteligente verificar a potência de todos os geradores e ao final fazer o desligamento, ou não, dos geradores menos eficientes para o horário. Conseguindo assim, atender a demanda de forma eficiente, garantindo todos os parâmetros operacionais do sistema e reduzindo o consumo de combustível e poluentes na atmosfera.

Os geradores menos eficientes após as simulações foram P2 e P3, seu desligamento não causou perturbações ou instabilidade para geração da potência, não sofreu grandes variações, proporcionando uma geração de potência ótima para o sistema, além de possibilitar a manutenção preditiva à medida que os geradores são desligados.

Por outro lado, o gerador P1 apresentou menor potência nas simulações, mas a técnica DE apresentou melhor desempenho. O gerador P4 apresentou variações mais significativas em

relação ao gerador P1, quando aplicada as técnicas de otimizações. O mesmo ocorreu para os demais geradores P5 e P6.

Nos resultados obtidos com as três técnicas (ALO, DA e DE) em relação à técnica de (KHAN et al., 2015) PSO, aplicada às 11h00, obtivemos uma redução média de **2,01%** correspondente a \$ **792.56** no custo do combustível com auxílio do uso de energia solar fotovoltaica. A redução média de poluentes na atmosfera foi de aproximadamente **29.58%**.

A Figura 24 exibe a comparação entre potência e emissão por gerador simulado na técnica *Ant Lion Optimizer* outro ponto destacado na Figura 25 que é o custo de combustível por geradores também simulado com a técnica *Ant Lion Optimizer*.

Na Figura 26 é exibida a simulação da técnica *Drangonflay Algorithms* que é a comparação entre potência e emissão apresentando outros resultados para a demanda solicitada, e na Figura 27 exibe o custo de combustível utilizado por cada gerador simulado na técnica *Drangonflay Algorithms*.

Na Figura 28 usando os mesmos critérios de simulação, é comparado a potência e emissão dos motores utilizando a técnica *Differential Evolution* que entre as outras técnicas apresentadas fornece resultados mais favoráveis para o horário demandado, da mesma forma, a Figura 29 robustece a sistemática do *Differential Evolution* de economia, apresentando resultados mais favoráveis todo esse contexto é apresentado nos resultados dos dados obtidos na Tabela 14, que representam os valores de potência, emissões e custos de combustível gerados pelas técnicas (ALO, DA e DE) às 11h00. Por fim, na Figura 30 é exibido o gráfico de Pareto da técnica DE comparando custo e emissões por ser a técnica que apresentou melhores resultados.

Figura 24 - Comparação entre Potência e Emissões por Geradores.




Figura 25 - Custo de Combustível por Geradores

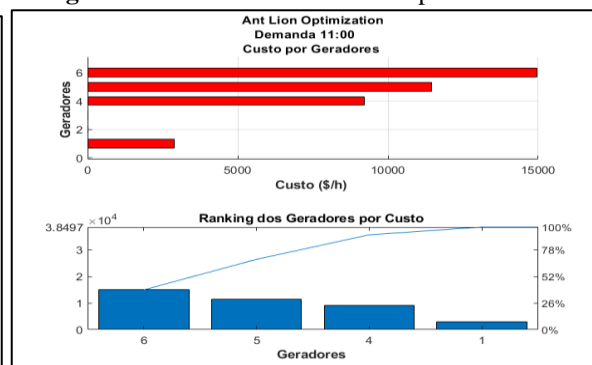


Figura 26 - Comparação entre Potência e Emissões por Geradores.

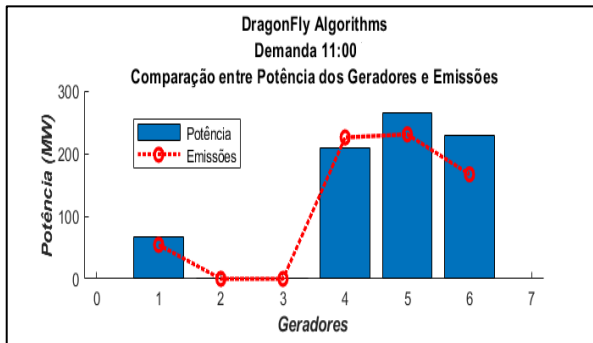


Figura 27 - Custo de Combustível por Geradores

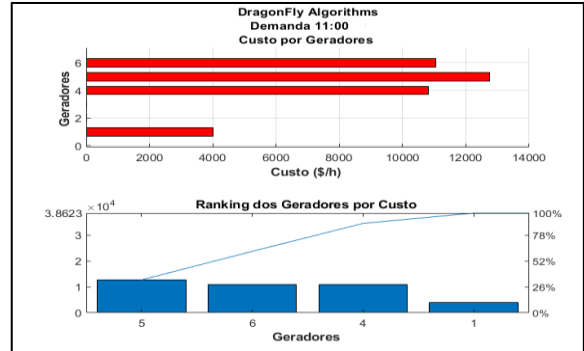


Figura 28 - Comparação entre Potência e Emissões por Geradores.

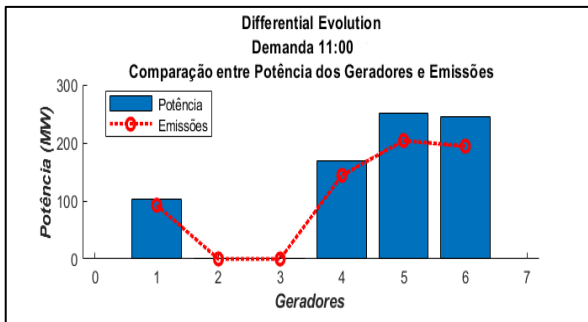


Figura 29 - Custo de Combustível por Geradores

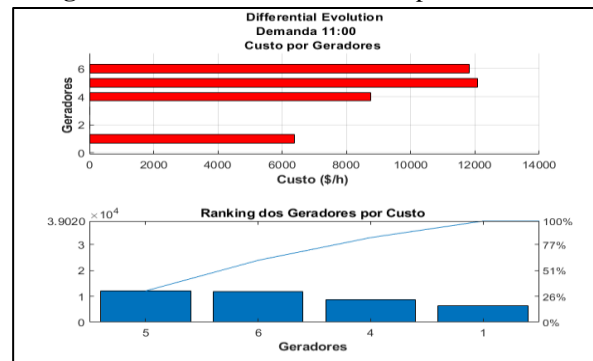
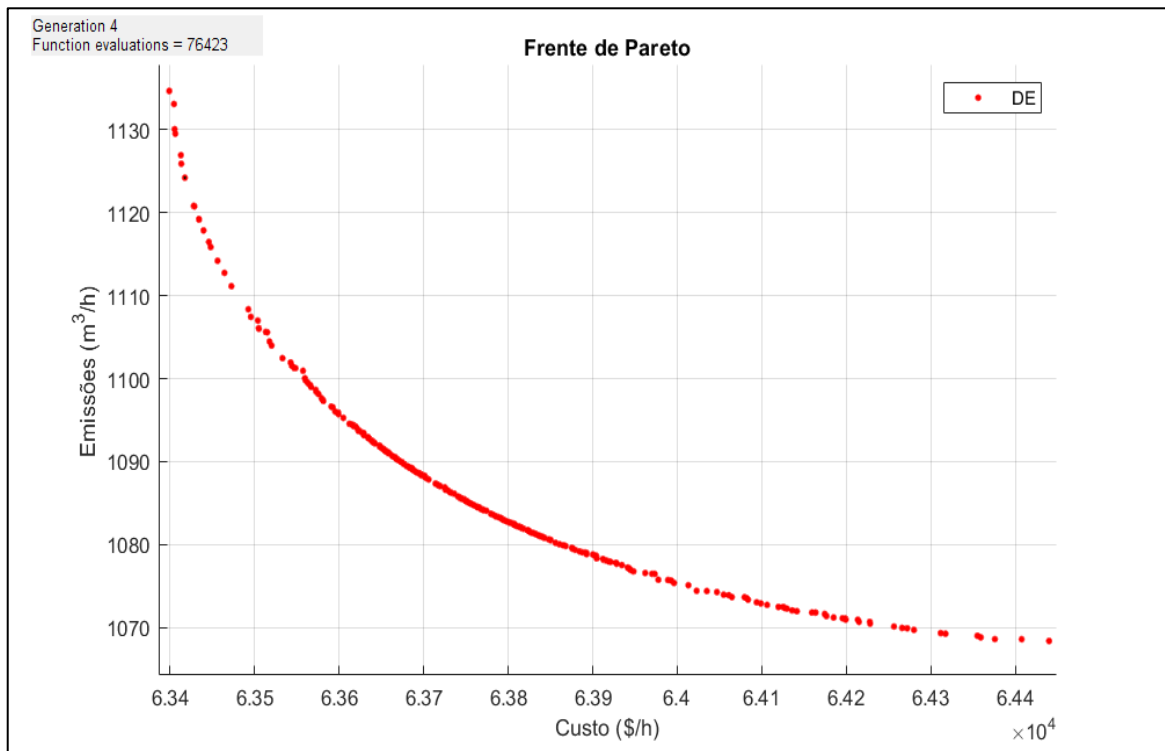


Figura 30 - Frente de Pareto técnica DE simulado às 11:00h.



Fonte: O Autor, (2022).

A Tabela 15, apresenta os resultados das simulações comparativas às 12h00, buscando atender a demanda total de 1240 MW de potência, incluindo a geração solar fotovoltaica.

Tabela 15 - Resultados da comparação com a energia solar para demanda de 1240 MW às 12h00.

Horário da Demanda: 12h				
Demanda Total do local (MW): 1240				
UG	Khan [8] PSO	ALO	DA	DE
P1 (MW)	10.0000	63.9146442	66.4929177	70.5542484
P2 (MW)	10.2191	0.0	0.0	0
P3 (MW)	194.9316	144.880293	153.967225	162.670872
P4 (MW)	177.4014	157.182434	149.767455	160.300776
P5 (MW)	224.8683	268.372194	269.246331	258.209833
P6 (MW)	303.5647	272.217041	267.105601	252.316865
Potência Elétrica (MW)	920.9851	906.5666	906.5795	904.0526
Potência Energia Solar (MW)	319.1076	336.0782	336.0782	336.0782
Potência Total (MW)	1240.0927	1242.64	1242.66	1240.13
Custo de Combustível (\$/h)	46,762.00	45,759.28	45,756.34	45,554.38
Emissões (m3)	860.70	805.03	788.41	746.88
Redução de Emissões (m3/h)	25.73%	27.05%	27.05%	27.10%

Fonte: O Autor, (2022).

Na tabela 15, percebe-se que a demanda de 1240 MW necessária para o cronograma é alcançada pelas três técnicas de otimização, e o algoritmo consegue de forma inteligente verificar a potência de todos os geradores e ao final faz o desligamento, ou não, dos geradores menos eficientes para o horário. Conseguindo assim, atender a demanda de forma eficiente, garantindo todos os parâmetros operacionais do sistema e reduzindo o consumo de combustível e poluentes na atmosfera. O gerador menos eficiente após as três técnicas simuladas foi o gerador P2, seu desligamento não causou perturbações ou instabilidade na geração da potência, não sofreu grandes variações, proporcionando uma geração de potência ótima para o sistema.

Por outro lado, o gerador P1 apresentou menor potência nas simulações, mas na técnica DE apresenta uma potência com melhor desempenho. Enquanto no gerador P3, as variações de potência foram mais significativas em relação ao gerador P1, quando aplicada as três técnicas. O mesmo ocorrendo para os demais geradores P4, P5 e P6.

Os resultados obtidos com as três técnicas (ALO, DA e DE) em relação à técnica PSO de (KHAN et al., 2015) aplicada às 12h00, obtivemos uma redução média de 2,29% correspondente a \$1,072.00 no custo do combustível com auxílio do uso de energia solar fotovoltaica. A redução média de poluentes na atmosfera foi de aproximadamente 27,06%.

A Figura 31 exibe a comparação entre potência e emissão por gerador simulado na técnica *Ant Lion Optimizer* outro ponto destacado na Figura 32 que é o custo de combustível por geradores também simulado com a técnica *Ant Lion Optimizer*.

Na Figura 33 é exibe a simulação da técnica *Drangonflay Algorithms* que é a comparação entre potência e emissão apresentando outros resultados para a demanda solicitada, e na Figura 34 exibe o custo de combustível utilizado por cada gerador simulado na técnica *Drangonflay Algorithms*.

Na Figura 35 usando os mesmos critérios de simulação, é comparado a potência e emissão dos motores utilizando a técnica *Differential Evolution* que entre as outras técnicas apresentadas fornece resultados mais favoráveis para o horário demandado, da mesma forma, a Figura 36 robustece a sistemática do *Differential Evolution* de economia, apresentando resultados mais favoráveis todo esse contexto é apresentado nos resultados dos dados obtidos na Tabela 15, que representam os valores de potência, emissões e custos de combustível gerados pelas técnicas (ALO, DA e DE) às 12h00.

Por fim, na Figura 37 é exibido o gráfico de Pareto da técnica DE comparando custo e emissões por ser a técnica que apresentou melhores resultados.

Figura 31 - Comparação entre Potência e Emissões por Geradores.

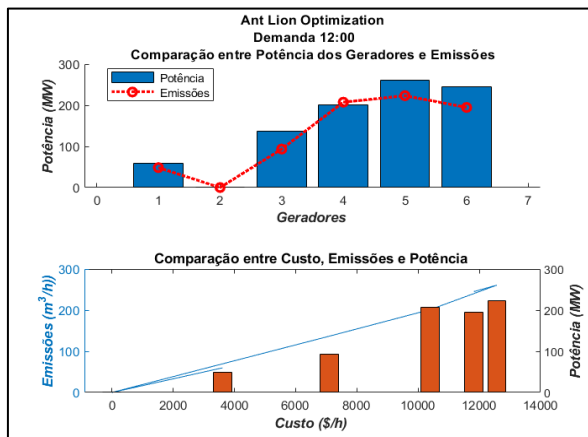


Figura 32 - Custo de Combustível por Geradores




Figura 33 - Comparação entre Potência e Emissões por Geradores.

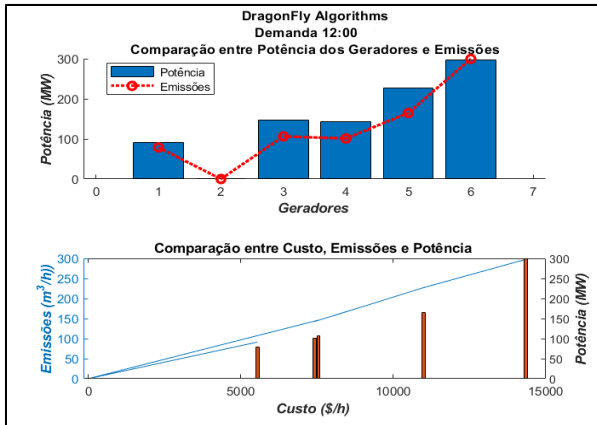


Figura 34 - Custo de Combustível por Geradores.




Figura 35 - Comparação entre Potência e Emissões por Geradores.

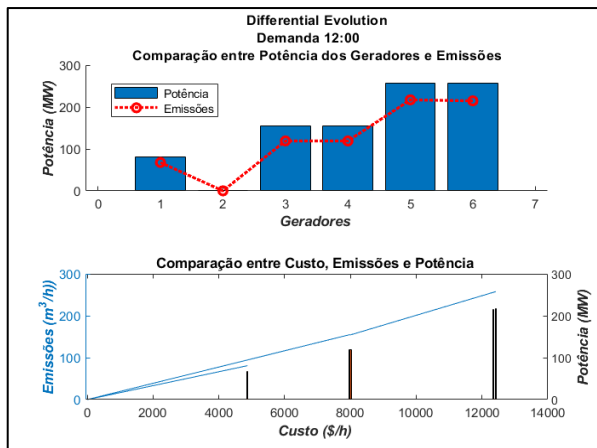


Figura 36 - Custo de Combustível por Geradores.





Figura 37 - Frente de Pareto técnica DE simulado às 12:00h.



Fonte: O Autor, (2022).

A Tabela 16, apresenta os resultados das simulações comparativas às 13h00, buscando atender a demanda total de 1135 MW de potência, incluindo a geração solar fotovoltaica.

Tabela 16 - Resultados da comparação com a energia solar para demanda de 1135 MW às 13:00h.

Horário da Demanda: 13h				
Demanda total do local (MW): 1135				
UG	Khan [8] PSO	ALO	DA	DE
P1 (MW)	10.8593	61.5364245	54.3228655	63.1154645
P2 (MW)	118.1312	0.0	0.0	0.0
P3 (MW)	147.9272	169.5	147.2	150.1
P4 (MW)	186.3632	120.877228	139.385491	148.32997
P5 (MW)	150.7713	253.236273	249.955496	238.76099
P6 (MW)	221.0182	230.654541	246.46383	233.390138
Potência Elétrica (MW)	835.0704	835.8243	837.3543	833.6587
Potência Energia Solar (MW)	300.0974	301.3746	301.3746	301.3746
Potência Total (MW)	1135.1678	1137.20	1138.73	1135.03
Custo de Combustível (\$/h)	44,136.00	42,432.17	42,402.33	42,078.57
Emissões (m3)	639.50	691.26	694.70	633.08
Redução de Emissões (m3/h)	26.44%	26.50%	26.47%	26.55%

Fonte: O Autor, (2022).

Na tabela 16, percebe-se que a demanda de 1135 MW necessária para o cronograma é alcançada pelas três técnicas de otimização, e o algoritmo consegue de forma inteligente verificar a potência de todos os geradores e ao final fazer o desligamento, ou não, dos geradores menos eficientes para o horário. Conseguindo assim, atender a demanda de forma eficiente, garantindo todos os parâmetros operacionais do sistema e reduzindo o consumo de combustível e poluentes na atmosfera. O gerador menos eficiente após as três técnicas simuladas foi o gerador P2, seu desligamento não causou perturbações ou instabilidade na geração da potência, não sofreu grandes variações, proporcionando uma distribuição de potência entre os seis (06) geradores de forma mais eficiente e garantindo o bom funcionamento do sistema.

Por outro lado, o gerador P1 apresentou menor potência nas simulações, mas na técnica DE, apresenta uma potência com melhor desempenho. Enquanto no gerador P3, as variações de potência foram mais significativas em relação ao gerador P1, quando aplicada as três técnicas. O mesmo ocorrendo para os demais geradores P4, P5 e P6.

Os resultados obtidos com as três técnicas (ALO, DA e DE) em relação à técnica PSO de (KHAN et al., 2015), aplicada às 13:00h, obtivemos uma redução média de 4,15% correspondente a \$1,831.64 no custo do combustível com auxílio do uso de energia solar fotovoltaica. A redução média de poluentes na atmosfera foi de aproximadamente 26,51%.

A Figura 38 exibe a comparação entre potência e emissão por gerador simulado na técnica *Ant Lion Optimizer* outro ponto destacado na Figura 39 que é o custo de combustível por geradores também simulado com a técnica *Ant Lion Optimizer*.

Na Figura 40 é exibida a simulação da técnica *Dragonfly Algorithms* que é a comparação entre potência e emissão apresentando outros resultados para a demanda solicitada, e na Figura 41 exibe o custo de combustível utilizado por cada gerador simulado na técnica *Dragonfly Algorithms*.

Na Figura 42 usando os mesmos critérios de simulação, é comparado a potência e emissão dos motores utilizando a técnica *Differential Evolution* que entre as outras técnicas apresentadas fornece resultados mais favoráveis para o horário demandado, da mesma forma, a Figura 43 robustece a sistemática do *Differential Evolution* de economia, apresentando resultados mais favoráveis todo esse contexto é apresentado nos resultados dos dados obtidos na Tabela 16, que representam os valores de potência, emissões e custos de combustível gerados pelas técnicas (ALO, DA e DE) às 13:00h.

Por fim, na Figura 44 é exibido o gráfico de Pareto da técnica DE comparando custo e emissões por ser a técnica que apresentou melhores resultados.

Figura 38 - Comparação entre Potência e Emissões por Geradores.




Figura 39 - Custo de Combustível por Geradores.




Figura 40 - Comparação entre Potência e Emissões por Geradores.

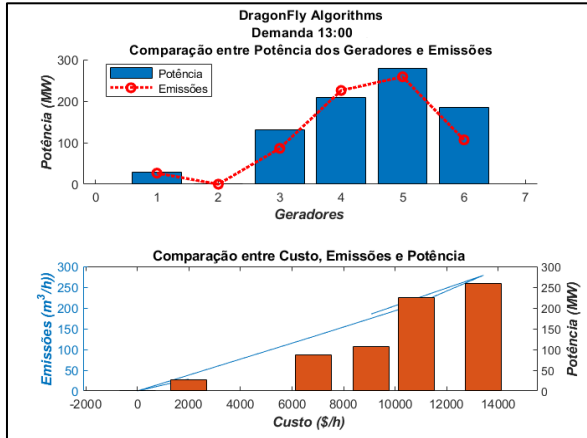


Figura 41 - Custo de Combustível por Geradores.




Figura 42 - Comparação entre Potência e Emissões por Geradores.

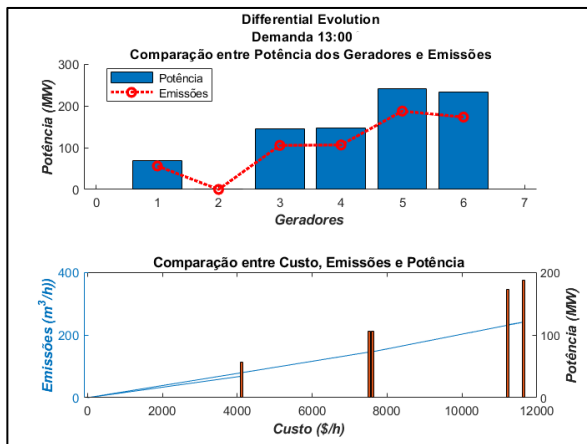


Figura 43 - Custo de Combustível por Geradores.

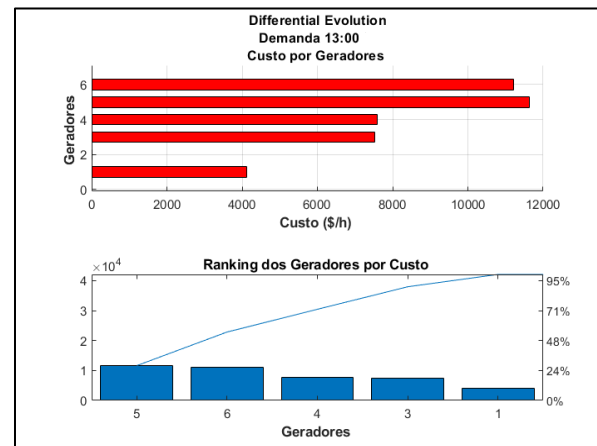



Figura 44 - Frente de Pareto técnica DE simulado às 13:00.



Fonte: O Autor, (2022).

A Tabela 17, apresenta os resultados das simulações comparativas às 14:00h, buscando atender a demanda total de 1318 MW de potência, incluindo a geração solar fotovoltaica.

Tabela 17 - Resultados da comparação com a energia solar para demanda de 1318 MW às 14:00h.

Horário da Demanda: 14h				
Demanda Total do local (MW): 1318				
UG	Khan [8] PSO	ALO	DA	DE
P1 (MW)	65.2834	60.4565214	65.7301939	72.9521692
P2 (MW)	97.2893	73.8477619	54.8034359	63.4803754
P3 (MW)	250	194.970962	187.038216	175.142017
P4 (MW)	107.6407	156.753484	185.409803	169.687328
P5 (MW)	252.7949	302.400902	289.265404	302.192304
P6 (MW)	297.7576	281.551494	286.46887	286.252958
Potência Elétrica (MW)	1070.7659	1069.9811	1068.7159	1069.7072
Potência Energia Solar (MW)	247.1655	252.221	252.221	252.221
Potência Total (MW)	1317.9314	1322.20	1320.94	1321.93
Custo de Combustível (\$/h)	55,082.00	54,716.55	54,399.74	54,356.73
Emissões (m3)	1,037.60	1,038.42	1,026.72	997.87
Redução de Emissões (m3/h)	18.75%	19.08%	19.09%	19.08%

Fonte: O Autor, (2022).

Na tabela 17, percebe-se que a demanda de 1318 MW necessária para o cronograma é alcançada pelas três técnicas de otimização, e o algoritmo consegue de forma inteligente verificar a potência de todos os seis (6) geradores, mas não consegue desligar os geradores devido à demanda requerida para o horário. Com a aplicação das técnicas, conseguimos atender a demanda de forma eficiente, garantindo todos os parâmetros operacionais do sistema, reduzindo o consumo de combustível e poluentes na atmosfera.

Os geradores P1 e P2 apresentaram menor potência nas simulações, mas na técnica ALO, apresentam uma potência com melhor desempenho. Enquanto no gerador P3, as variações de potência foram mais significativas em relação aos geradores P1 e P2, quando aplicada as três técnicas. O mesmo ocorrendo para os demais geradores P4, P5 e P6.

Os resultados obtidos com as três técnicas (ALO, DA e DE) em relação à técnica PSO de Khan, (2015), aplicada às 14:00h, obtivemos uma redução média de 1,07% correspondente

a \$ 590.99 no custo do combustível com auxílio do uso de energia solar fotovoltaica. A redução média de poluentes na atmosfera foi de aproximadamente 19,08%.

A Figura 45 exibe a comparação entre potência e emissão por gerador simulado na técnica *Ant Lion Optimizer* outro ponto destacado na Figura 46 que é o custo de combustível por geradores também simulado com a técnica *Ant Lion Optimizer*.

Na Figura 47 é exibe a simulação da técnica *Drangonflay Algorithms* que é a comparação entre potência e emissão apresentando outros resultados para a demanda solicitada, e na Figura 48 exibe o custo de combustível utilizado por cada gerador simulado na técnica *Drangonflay Algorithms*.

Na Figura 49 usando os mesmos critérios de simulação, é comparado a potência e emissão dos motores utilizando a técnica *Differential Evolution* que entre as outras técnicas apresentadas fornece resultados mais favoráveis para o horário demandado, da mesma forma, a Figura 50 robustece a sistemática do *Differential Evolution* de economia, apresentando resultados mais favoráveis todo esse contexto é apresentado nos resultados dos dados obtidos na Tabela 17, que representam os valores de potência, emissões e custos de combustível gerados pelas técnicas (ALO, DA e DE) às 14:00h.

Por fim, na Figura 51 é exibido o gráfico de Pareto da técnica DE comparando custo e emissões por ser a técnica que apresentou melhores resultados.

Figura 45 - Comparação entre Potência e Emissões por Geradores.




Figura 46 - Custo de Combustível por Geradores.




Figura 47 - Comparação entre Potência e Emissões por Geradores.

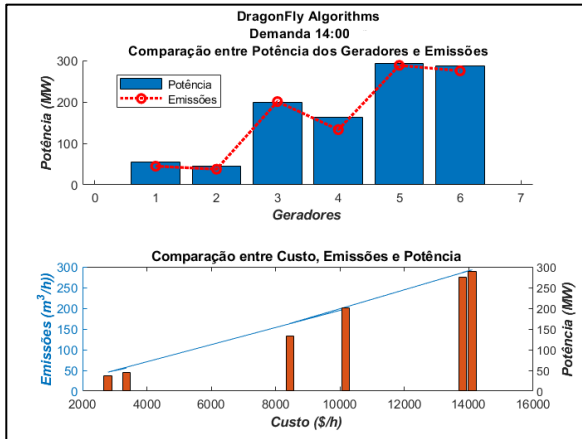


Figura 48 - Custo de Combustível por Geradores.




Figura 49 - Comparação entre Potência e Emissões por Geradores.

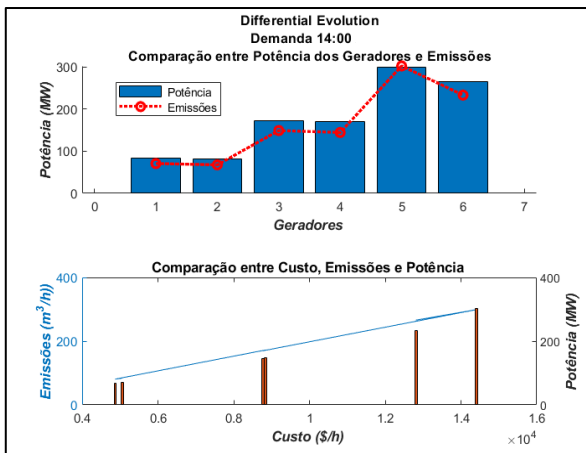


Figura 50 - Custo de Combustível por Geradores.





Figura 51 - Frente de Pareto técnica DE simulado às 14:00h.



Fonte: O Autor, (2022)

A Tabela 18, apresenta os resultados das simulações comparativas às 15:00h, buscando atender a demanda total de 1074 MW de potência, incluindo a geração solar fotovoltaica.

Tabela 18 - Resultados da comparação com a energia solar para demanda de 1074 MW às 15h00.

Horário da Demanda: 15h				
Demanda Total do local (MW): 1074				
UG	Khan [8] PSO	ALO	DA	DE
P1 (MW)	82.7064	52.9765892	60.0407279	66.3375108
P2 (MW)	60.696	0.0	0.0	0.0
P3 (MW)	249.2579	173.381284	134.867754	153.227035
P4 (MW)	96.2554	144.11171	154.516488	153.137594
P5 (MW)	182.7257	232.944996	264.668814	242.575939
P6 (MW)	190.6486	256.432008	244.797922	242.691691
Potência Elétrica (MW)	862.29	859.8466	858.8917	857.9698
Potência Energia Solar (MW)	211.7604	216.0917	216.0917	216.0917
Potência Total (MW)	1074.0504	1075.94	1074.98	1074.06
Custo de Combustível (\$/h)	45,057.00	43,539.57	43,466.22	43,303.60
Emissões (m3)	714.90	728.28	719.58	671.93
Redução de Emissões (m3/h)	19.72%	20.08%	20.10%	20.12%

Fonte: O Autor, (2022).

Na tabela 18, percebe-se que a demanda de 1074 MW necessária para o cronograma é alcançada pelas três técnicas de otimização, e o algoritmo consegue de forma inteligente verificar a potência de todos os geradores e ao final fazer o desligamento dos geradores menos eficientes para o horário. Conseguindo assim, atender a demanda de forma eficiente, garantindo todos os parâmetros operacionais do sistema e reduzindo o consumo de combustível e poluentes na atmosfera. O gerador menos eficiente após as três técnicas simuladas foi o gerador P2, seu desligamento não causou perturbações ou instabilidade na geração da potência, não sofreu grandes variações, proporcionando uma distribuição de potência entre os seis (06) geradores de forma mais eficiente e garantindo o bom funcionamento do sistema.

Por outro lado, o gerador P1 apresentou menor potência nas simulações, mas na técnica DE apresenta uma potência com melhor desempenho. Enquanto no gerador P3, as variações de potência foram mais significativas em relação ao gerador P1, quando aplicada as três técnicas. O mesmo ocorrendo para os demais geradores P4, P5 e P6.

Os resultados obtidos com as três técnicas (ALO, DA e DE) em relação à técnica PSO de (KHAN et al., 2015b), aplicada às 15h00, obtivemos uma redução média de 3,60% correspondente a \$1,620.54 no custo do combustível com auxílio do uso de energia solar fotovoltaica. A redução média de poluentes na atmosfera foi de aproximadamente 20,10%.

A Figura 52 exibe a comparação entre potência e emissão por gerador simulado na técnica *Ant Lion Optimizer* outro ponto destacado na Figura 53 que é o custo de combustível por geradores também simulado com a técnica *Ant Lion Optimizer*.

Na Figura 54 é exibe a simulação da técnica *Drangonflay Algorithms* que é a comparação entre potência e emissão apresentando outros resultados para a demanda solicitada, e na Figura 55 exibe o custo de combustível utilizado por cada gerador simulado na técnica *Drangonflay Algorithms*.

Na Figura 56 usando os mesmos critérios de simulação, é comparado a potência e emissão dos motores utilizando a técnica *Differential Evolution* que entre as outras técnicas apresentadas fornece resultados mais favoráveis para o horário demandado, da mesma forma, a Figura 57 robustece a sistemática do *Differential Evolution* de economia, apresentando resultados mais favoráveis todo esse contexto é apresentado nos resultados dos dados obtidos na Tabela 18, que representam os valores de potência, emissões e custos de combustível gerados pelas técnicas (ALO, DA e DE) às 15:00h.

Por fim, na Figura 58 é exibido o gráfico de Pareto da técnica DE comparando custo e emissões por ser a técnica que apresentou melhores resultados.

Figura 52 - Comparação entre Potência e Emissões por Geradores.

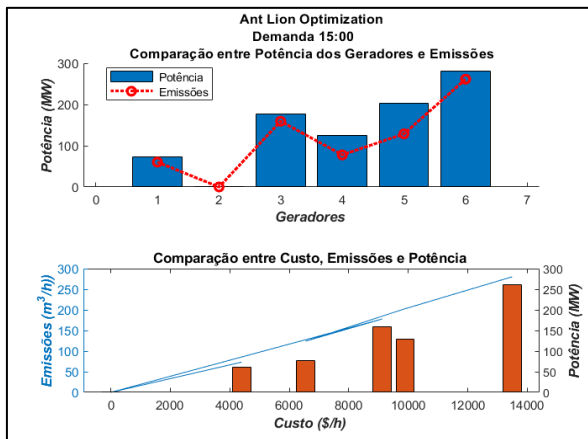


Figura 53 - Custo de Combustível por Geradores.




Figura 54 - Comparação entre Potência e Emissões por Geradores.

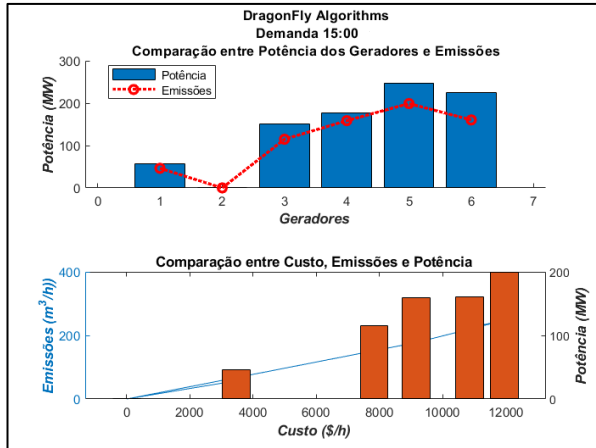


Figura 55 - Custo de Combustível por Geradores.

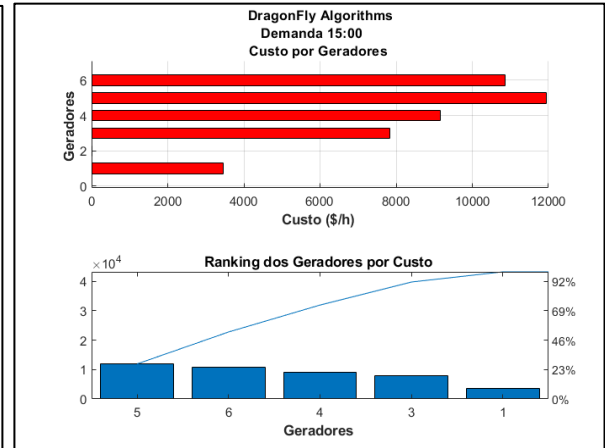


Figura 56 - Comparação entre Potência e Emissões por Geradores.

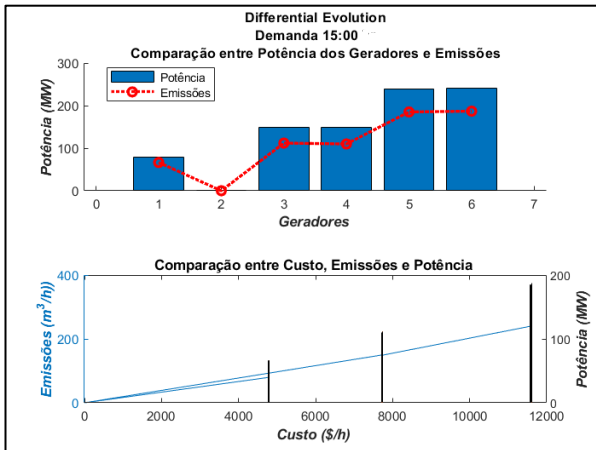


Figura 57 - Custo de Combustível por Geradores.





Figura 58 - Frente de Pareto técnica DE simulado às 15:00h.



Fonte: O Autor, (2022).

A Tabela 19, apresenta as técnicas metaheurísticas simuladas das 10:00h às 15:00h, comparando o custo total de combustível entre as quatro técnicas simuladas e os resultados alcançados por cada técnica. Observamos que a técnica DE obteve a melhor redução de custo de combustível em todas as seis simulações, DA obteve o segundo melhor resultado, ALO ficou em terceiro lugar, o que demonstra que as três técnicas obtiveram melhores resultados que a técnica PSO.


Tabela 19 - Comparação do custo total de combustível entre as técnicas.

Hora	PSO	ALO		DA		DE	
	Custo de Combustível (\$/h)	Custo de Combustível (\$/h)	Redução %	Custo de Combustível (\$/h)	Redução %	Custo de Combustível (\$/h)	Redução %
10:00	52,626.00	50,782.54	3.50	50,712.79	3.64	50,654.61	3.75
11:00	39,426.00	38,706.90	1.82	38,609.38	2.07	38,584.03	2.07
12:00	46,762.00	45,759.28	2.14	45,756.34	2.15	45,554.38	2.58
13:00	44,136.00	42,432.17	3.86	42,402.33	3.93	42,078.57	4.66
14:00	55,082.00	54,716.55	0.66	54,399.74	1.24	54,356.73	1.32
15:00	45,057.00	43,539.57	3.37	43,466.22	3.53	43,303.60	3.89
Total	283,089.00	275,937.02	2.53	275,346.79	2.73	274,531.92	3.02

Fonte: O Autor, (2022).

Os algoritmos propostos mantiveram os geradores em sua potência ótima para obter sempre a melhor eficiência. A nova proposta mostra que dentre as técnicas utilizadas, a técnica DE foi a melhor, garantindo a redução do uso de combustível fóssil em 3,02%, correspondente a \$ 8,557.08, redução de DA em 2,73%, correspondente a \$ 7,742.21, enquanto ALO obteve a menor redução 2,53%, correspondente a \$ 7,151.98. Os resultados foram comparados com a técnica PSO.

Durante as simulações, a maior redução ocorreu às 13h. com 4,66% e a menor redução ocorreu às 14h com 1,32%. A Figura 59, mostra os resultados dos dados obtidos na Tabela 19, em que o custo geral do combustível obtido entre 10h e 15h, obtém o melhor desempenho (redução de custo) com a técnica DE.

Figura 59 - Total geral do custo de combustível simulado entre as técnicas de otimização.

Fonte: O Autor, (2022).

A Tabela 20, apresenta uma comparação em percentual das emissões obtidas por cada técnica entre o intervalo de 10:00 da manhã e 15:00 da tarde. Na coluna de redução média, é calculado a média somente das três técnicas proposta (ALO, DA e DE), para ser comparada entre as simulações de (KHAN et al., 2015) usando PSO.


Tabela 20 – Redução das emissões entre as técnicas de otimização.

Hora	PSO	ALO	DA	DE	Redução Média %
	Redução Emissão %	Redução Emissão %	Redução Emissão %	Redução Emissão %	
10:00	19.20%	19.17%	19.18%	19.21%	19.19%
11:00	29.18%	29.54%	29.58%	29.63%	29.58%
12:00	25.73%	27.05%	27.05%	27.10%	27.07%
13:00	26.44%	26.50%	26.47%	26.55%	26.51%
14:00	18.75%	19.08%	19.09%	19.08%	19.08%
15:00	19.72%	20.08%	20.10%	20.12%	20.10%
Total	1.39%	1.41%	1.41%	1.42%	

Fonte: O autor, (2022).

Conforme apresentado na Tabela 20, observa-se que às 10:00h a técnica PSO apresentou o valor de 19.20% e a nova proposta apresenta uma média no valor de 19.19% entre ALO, DA e DE. Da mesma forma às 11:00h o valor apresentado pelo PSO foi de 29.18% e a nova proposta apresenta uma média no valor de 29.58%. De forma análoga os valores são apresentados até às 15:00h, onde o PSO apresenta o valor de 19.72% e a nova proposta atinge uma média de 20.10%. Dessa forma, as simulações ocorridas em cada intervalo de uma hora estão demonstradas na tabela acima. A Figura 60, exibe os resultados dos dados obtidos na Tabela 20, onde os valores de redução das emissões são apresentados em percentual por cada técnica de otimização entre o intervalo de 10:00 da manhã e 15:00 da tarde, a técnica DE obteve melhor desempenho (redução de poluentes) na atmosfera.

Figura 60 – Redução das Emissões entre as técnicas de otimização utilizadas.



Fonte: O Autor, (2022).

Os resultados da simulação apresentam um esforço de baixo custo computacional, que ao se decidir qual o gerador térmico não será utilizado no planejamento da operação, o algoritmo seleciona a potência ótima de cada unidade geradora para obter a melhor eficiência e desempenho de resposta. Os métodos apresentam bons resultados, mesmo com escolhas de forma inteligente para o sistema, permitindo realizar o planejamento de curto e longo prazo das operações com mais eficiência.

5.6 Considerações Finais do Capítulo V

Neste capítulo foram descritos os procedimentos computacionais usados nesta tese para resolver o problema do DEA utilizando as técnicas metaheurísticas *Ant Lion Optimizer (ALO)*, *DragonFly Algorithm (DA)* e *Differential Evolution (DE)*.

Nesse sentido, a proposta da presente tese é apresentar um comparativo entre diversas técnicas metaheurísticas na otimização das soluções do DEA, incluindo a geração de energia solar fotovoltaica e o desligamento dos motores menos eficientes, bem como auxiliar o especialista na tomada de decisão para o funcionamento da planta geradora.

As simulações foram implementadas no ambiente do MATLAB, o modelo proposto considera uma demanda de 100% a ser atendida, e por questões de segurança foi utilizada 70% da capacidade das usinas solares fotovoltaicas, devido à instabilidade da geração solar, sendo o restante da demanda atendido pela usina termoelétrica. No percentual a ser atendido pela termoelétrica, é aplicada a otimização para o problema DEA, considerando um sistema teste com 6 UG para suprir a necessidade da demanda.

As configurações de controle usadas para as simulações foram: $C1, C2 = 2$; $r1, r2 =$ números aleatórios entre 0 e 1; número máximo de iterações = 1500 com populações variando entre 100, 200 e 300 indivíduos. Os resultados obtidos pelas técnicas metaheurísticas foram apresentados em forma de tabela e gráficos. No próximo capítulo, é descrito o fechamento dos resultados obtidos pelas técnicas metaheurísticas e outras propostas para continuidade desse estudo.

CAPÍTULO VI

6 CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS

Nesta tese são implementados métodos de otimização aplicados na geração de energia elétrica com a integração de fontes renováveis fotovoltaicas, apresentando uma solução viável para a geração de energia mais limpa e sustentável. É proposta uma nova solução para o problema de otimização do DEA, aplicado a um sistema híbrido composto por uma usina termoelétrica e usina solar fotovoltaica.

A modelagem do problema do Despacho Econômico e Ambiental para definição dos melhores resultados entre as técnicas ALO, DA e DE mostrou que com a técnica DE, obteve-se reduções significativas tanto no consumo de combustível como nas emissões de poluentes para a atmosfera. A utilização da plataforma computacional MATLAB para as simulações dos resultados mostrou-se interativa e de simples utilização para implementação das metaheurísticas ALO, DA e DE, proporcionando relatórios numéricos e gráficos robustos que permitiram uma análise mais precisa dos resultados. Foi possível verificar o impacto da inserção da energia solar fotovoltaica na contribuição do atendimento da demanda de geração de energia pelas UTE, bem como os benefícios do desligamento inteligente dos geradores menos eficientes, tanto para a geração de potência elétrica quanto nas emissões de poluentes.

Ao se optar pela geração de energia a partir de usinas fotovoltaicas para atender a demanda energética, obtêm-se uma produção mais limpa de energia elétrica e com menor impacto ambiental, contribuindo para a redução dos poluentes lançados na atmosfera. O novo método verifica de forma inteligente a capacidade dos geradores em uso e, dependendo da demanda solicitada para o horário, desliga ou não o gerador térmico menos eficiente.

Com a implementação do DEA em um sistema híbrido é possível atender a demanda de energia de forma eficiente, respeitando todas as restrições de operação do sistema, reduzindo custos com combustível e emissões de poluentes na atmosfera. Neste sentido, a aplicação de metaheurísticas para otimizar o DEA mostrou-se eficiente e confiável na geração de energia. Por fim, com os resultados obtidos nesta tese, desenvolveu-se um artigo original no Periódico Energies intitulado: “Rational Application of Electric Power Production Optimization through Metaheuristics Algorithm”, Santos Eliton, Nunes Marcus, Nascimento Manoel, Leite Jandecy.

6.1 Propostas para Trabalhos Futuros

Com os resultados alcançados até o presente momento, pode-se considerar as seguintes pesquisas para o futuro:

- ✓ Desenvolver uma aplicação para determinar dinamicamente as potências de cada unidade geradora;
- ✓ Aplicar a metodologia utilizada nesta tese para outras técnicas metaheurísticas multiobjetivo.
- ✓ Avaliar a metodologia para sistemas de geração híbrida com uso de outras fontes de energia limpa e renováveis.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABAS, N.; KALAIR, A.; KHAN, N. Review of fossil fuels and future energy technologies. **Futures**, v. 69, p. 31–49, 2015.
- ABDILAH, A. M.; MUSTAFA, M. W. Carbon capture power plants: Decoupled emission and generation outputs for economic dispatch. **International Journal of Greenhouse Gas Control**, v. 63, p. 12–19, 2017.
- AFANDI, A. N. Thunderstorm algorithm for assessing thermal power plants of the integrated power system operation with an environmental requirement. **International Journal of Engineering and Technology**, v. 8, n. 2, p. 1102–1111, 2016.
- AFANDI, A. N.; MIYAUCHI, H. Solving combined economic and emission dispatch using harvest season artificial bee colony algorithm considering food source placements and modified rates. **International journal on electrical engineering and informatics**, v. 6, n. 2, p. 266, 2014.
- AHMADI, M. H. et al. Solar power technology for electricity generation: A critical review. **Energy Science & Engineering**, v. 6, n. 5, p. 340–361, 2018.
- AL-MAAMARY, H. M.; KAZEM, H. A.; CHAICHAN, M. T. Renewable energy and GCC States energy challenges in the 21st century: A review. **International Journal of Computation and Applied Sciences IJOCAAS**, v. 2, n. 1, p. 11–18, 2017.
- ALVES, L. A.; UTURBEY, W. Environmental degradation costs in electricity generation: The case of the Brazilian electrical matrix. **Energy Policy**, v. 38, n. 10, p. 6204–6214, 2010.
- ANTUNES, C. H.; HENRIQUES, C. O. Multi-objective optimization and multi-criteria analysis models and methods for problems in the energy sector. Em: **Multiple criteria decision analysis**. [s.l.] Springer, 2016. p. 1067–1165.
- ARUL, R.; RAVI, G.; VELUSAMI, S. An improved harmony search algorithm to solve economic load dispatch problems with generator constraints. **Electrical Engineering**, v. 96, n. 1, p. 55–63, 2014.
- BARONI, B. R. et al. Impact of photovoltaic generation on the allowed revenue of the utilities considering the lifespan of transformers: A Brazilian case study. **Electric Power Systems Research**, v. 192, p. 106906, 2021.
- BASU, M. Fuel constrained economic emission dispatch using nondominated sorting genetic algorithm-II. **Energy**, v. 78, p. 649–664, 2014.
- BASU, M. Multi-objective optimal reactive power dispatch using multi-objective differential evolution. **International Journal of Electrical Power & Energy Systems**, v. 82, p. 213–224, 2016.
- BELLHOUSE, G. M.; WHITTINGTON, H. W. Simulation of gaseous emissions from electricity generating plant. **International Journal of Electrical Power & Energy Systems**, v. 18, n. 8, p. 501–507, 1996.

BRINI, S.; ABDALLAH, H. H.; OUALI, A. Economic dispatch for power system included wind and solar thermal energy. **Leonardo Journal of Sciences**, v. 14, n. 2009, p. 204–220, 2009a.

BRINI, S.; ABDALLAH, H. H.; OUALI, A. Economic dispatch for power system included wind and solar thermal energy. **Leonardo Journal of Sciences**, v. 14, n. 2009, p. 204–220, 2009b.

CARAMIA, M.; DELL'OLMO, P. Embedding a novel objective function in a two-phased local search for robust vertex coloring. **European journal of operational research**, v. 189, n. 3, p. 1358–1380, 2008.

CARAMIA, M.; DELL'OLMO, P. Multi-objective optimization. Em: **Multi-objective management in freight logistics**. [s.l.] Springer, 2020. p. 21–51.

CARRIÇO, J. et al. Technical and economic assessment of a 450 W autonomous photovoltaic system with lithium iron phosphate battery storage. **Journal of Sustainable Development of Energy, Water and Environment Systems**, v. 6, n. 1, p. 129–149, 2018.

CLEARY, B. et al. Estimating the electricity prices, generation costs and CO₂ emissions of large scale wind energy exports from Ireland to Great Britain. **Energy Policy**, v. 91, p. 38–48, 2016.

COELLO, C. A. C. A comprehensive survey of evolutionary-based multiobjective optimization techniques. **Knowledge and Information systems**, v. 1, n. 3, p. 269–308, 1999.

CONAMA. Resolução No 357, de 17 de Março de 2006. Conselho Nacional do Meio Ambiente-CONAMA, v. 357, 2006. v. 357, 2006.

CURTIS, J.; LYNCH, M. Á.; ZUBIATE, L. Carbon dioxide (CO₂) emissions from electricity: The influence of the North Atlantic Oscillation. **Applied energy**, v. 161, p. 487–496, 2016.

DARYANI, N.; ZARE, K. Multiobjective power and emission dispatch using modified group search optimization method. **Ain Shams Engineering Journal**, v. 9, n. 3, p. 319–328, 2018.

DAS, D.; BHATTACHARYA, A.; RAY, R. N. Dragonfly algorithm for solving probabilistic economic load dispatch problems. **Neural Computing and Applications**, v. 32, n. 8, p. 3029–3045, 2020.

DE ANDRADE, J. V. B. et al. Constitutional aspects of distributed generation policies for promoting Brazilian economic development. **Energy Policy**, v. 143, p. 111555, 2020.

DEB, K.; ALGORITHMS, M.-O. O. U. E. Wiley, Chichester, UK. **Google Scholar Google Scholar Digital Library Digital Library**, 2001.

DEB, S. et al. Recent Methodology-Based Gradient-Based Optimizer for Economic Load Dispatch Problem. **IEEE Access**, v. 9, p. 44322–44338, 2021.

DELARUE, E.; VAN DEN BERGH, K. Carbon mitigation in the electric power sector under cap-and-trade and renewables policies. **Energy Policy**, v. 92, p. 34–44, 2016.

DENG, W. et al. An improved differential evolution algorithm and its application in optimization problem. **Soft Computing**, v. 25, n. 7, p. 5277–5298, abr. 2021.

DHAMANDA, A. et al. A traditional approach to solve economic load dispatch problem of thermal generating unit using MATLAB programming. **International Journal of Engineering Research & Technology (IJERT)**, v. 2, 2013.

DINIZ, F. L. J. et al. BALANÇO ENERGÉTICO E EXERGÉTICO DE SISTEMAS HÍBRIDOS PVT CONTENDO NANOFLUIDOS. **VII Congresso Brasileiro de Energia Solar - CBENS 2018**, 2018.

DIORIO, N. et al. **Technoeconomic modeling of battery energy storage in SAM**. [s.l.] National Renewable Energy Lab.(NREL), Golden, CO (United States), 2015.

EHRGOTT, M.; WIECEK, M. M. Multiobjective programming. Em: **Multiple criteria decision analysis: State of the art surveys**. [s.l.] Springer, 2005. p. 667–708.

ELLABBAN, O.; ABU-RUB, H.; BLAABJERG, F. Renewable energy resources: Current status, future prospects and their enabling technology. **Renewable and Sustainable Energy Reviews**, v. 39, p. 748–764, 2014.

EL-SHORBAGY, M. A.; MOUSA, A. A. Chaotic particle swarm optimization for imprecise combined economic and emission dispatch problem. **Review of Information Engineering and Applications**, v. 4, n. 1, p. 20–35, 2017.

EYRING, V. Emissions from international shipping: 2. Impact of future technologies on scenarios until 2050. **Journal of Geophysical Research**, v. 110, n. D17, p. D17306, 2005.

FILIPPI, C.; GUASTAROBA, G.; SPERANZA, M. G. A heuristic framework for the bi-objective enhanced index tracking problem. **Omega**, v. 65, p. 122–137, 2016.

FONSECA, C. M.; FLEMING, P. J. An overview of evolutionary algorithms in multiobjective optimization. **Evolutionary computation**, v. 3, n. 1, p. 1–16, 1995.

FOXON, T. J. **Energy and Economic Growth: Why we need a new pathway to prosperity**. [s.l.] Routledge, 2017.

GANDIBLEUX, X.; MEZDAOUI, N.; FRÉVILLE, A. A tabu search procedure to solve multiobjective combinatorial optimization problems. Em: **Advances in multiple objective and goal programming**. [s.l.] Springer, 1997. p. 291–300.

GITIZADEH, M.; GHAVIDEL, S. Improving transient stability with multi-objective allocation and parameter setting of SVC in a multi-machine power system. **IETE Journal of Research**, v. 60, n. 1, p. 33–41, 2014.

GOLDBERG, D. E.; SEGREST, P. **Finite Markov chain analysis of genetic algorithms**. Proceedings of the second international conference on genetic algorithms. **Anais...**1987.

GOYAL, S. K. et al. **Economic Load Dispatch with Emission and Line Constraints using Biogeography Based Optimization Technique**. 2020 International Conference on Intelligent Engineering and Management (ICIEM). **Anais...** Em: 2020 INTERNATIONAL

CONFERENCE ON INTELLIGENT ENGINEERING AND MANAGEMENT (ICIEM). jun. 2020.

GRANDE-ACOSTA, G.; ISLAS-SAMPERIO, J. Towards a low-carbon electric power system in Mexico. **Energy for Sustainable Development**, v. 37, p. 99–109, 2017.

GRANQVIST, C. G.; NIKLASSON, G. A. Solar energy materials for thermal applications: A primer. **Solar Energy Materials and Solar Cells**, v. 180, p. 213–226, 2018.

GURUNG, A.; QIAO, Q. Solar charging batteries: advances, challenges, and opportunities. **Joule**, v. 2, n. 7, p. 1217–1230, 2018.

HADJI, B. et al. Multi-objective economic emission dispatch solution using dance bee colony with dynamic step size. **Energy Procedia**, v. 74, p. 65–76, 2015.

HAJELA, P.; LIN, C.-Y. Genetic search strategies in multicriterion optimal design. **Structural optimization**, v. 4, n. 2, p. 99–107, 1992.

HALABI, L. M.; MEKHILEF, S. Flexible hybrid renewable energy system design for a typical remote village located in tropical climate. **Journal of cleaner production**, v. 177, p. 908–924, 2018.

HANSEN, M. P. Metaheuristics for multiple objective combinatorial optimization. 1998.

HASSELEIN, H. Otimização do Despacho Econômico de Carga de carga com a utilização de heurísticas bio-inspiradas, considerando um limite de penetração de fontes alternativas. 2021.

HASSLER, B. et al. **The application of long-term observations of NO_x and CO to constrain a global emissions inventory**. IGAC 2016 Science Conference (International Global Atmospheric Chemistry). **Anais...2016**.

HENNEMAN, L. R. et al. Assessing emissions levels and costs associated with climate and air pollution policies in South Africa. **Energy Policy**, v. 89, p. 160–170, 2016.

HOLLADAY, J. S.; LARIVIERE, J. The impact of cheap natural gas on marginal emissions from electricity generation and implications for energy policy. **Journal of Environmental Economics and Management**, v. 85, p. 205–227, 2017.

HOWARD, B.; WAITE, M.; MODI, V. Current and near-term GHG emissions factors from electricity production for New York State and New York City. **Applied energy**, v. 187, p. 255–271, 2017.

HUANG, W.-T. et al. Derivation and application of a new transmission loss formula for power system economic dispatch. **Energies**, v. 11, n. 2, p. 417, 2018.

HUSSAIN, I. et al. Performance analysis of flower pollination algorithm optimized PID controller for wind-PV-SMES-BESS-diesel autonomous hybrid power system. **International Journal of Renewable Energy Research (IJRER)**, v. 7, n. 2, p. 643–651, 2017.

INFIELD, D.; FRERIS, L. **Renewable energy in power systems**. [s.l.] John Wiley & Sons, 2020.

JAFARI, M.; BAYATI CHALESHTARI, M. H. Using dragonfly algorithm for optimization of orthotropic infinite plates with a quasi-triangular cut-out. **European Journal of Mechanics - A/Solids**, v. 66, p. 1–14, 1 nov. 2017.

JANKE, S. M. et al. Pentacene and tetracene molecules and films on H/Si (111): Level alignment from hybrid density functional theory. **Electronic Structure**, v. 2, n. 3, p. 035002, 2020.

JEBARAJ, L. et al. Application of differential evolution algorithm in static and dynamic economic or emission dispatch problem: A review. **Renewable and Sustainable Energy Reviews**, v. 77, p. 1206–1220, 2017.

KABIR, E. et al. Solar energy: Potential and future prospects. **Renewable and Sustainable Energy Reviews**, v. 82, p. 894–900, 2018.

KAMBOJ, V. K.; BHADORIA, A.; BATH, S. K. Solution of non-convex economic load dispatch problem for small-scale power systems using ant lion optimizer. **Neural Computing and Applications**, v. 28, n. 8, p. 2181–2192, 2017a.

KAMBOJ, V. K.; BHADORIA, A.; BATH, S. K. Solution of non-convex economic load dispatch problem for small-scale power systems using ant lion optimizer. **Neural Computing and Applications**, v. 28, n. 8, p. 2181–2192, 2017b.

KHAN, H. A.; PERVAIZ, S. Technological review on solar PV in Pakistan: Scope, practices and recommendations for optimized system design. **Renewable and sustainable energy reviews**, v. 23, p. 147–154, 2013.

KHAN, N. A. et al. Combined emission economic dispatch of power system including solar photo voltaic generation. **Energy Conversion and Management**, v. 92, p. 82–91, 2015c.

KHAN, N. A. et al. Combined emission economic dispatch of power system including solar photo voltaic generation. **Energy Conversion and management**, v. 92, p. 82–91, 2015a.

KHAN, N. A. et al. Combined emission economic dispatch of power system including solar photo voltaic generation. **Energy Conversion and management**, v. 92, p. 82–91, 2015b.

KHOA, T. H. et al. Solving economic dispatch problem with valve-point effects using swarm-based mean–variance mapping optimization (MVMOS). **Cogent Engineering**, v. 2, n. 1, p. 1076983, 2015.

KÖK, A. G.; SHANG, K.; YÜCEL, Ş. Impact of electricity pricing policies on renewable energy investments and carbon emissions. **Management Science**, v. 64, n. 1, p. 131–148, 2018.

LIN, Y.; BIAN, X.; DONG, Z. A discrete hybrid algorithm based on Differential Evolution and Cuckoo Search for optimizing the layout of ship pipe route. **Ocean Engineering**, v. 261, p. 112164, 1 out. 2022.

LIU, T. et al. Cultural quantum-behaved particle swarm optimization for environmental/economic dispatch. **Applied Soft Computing**, v. 48, p. 597–611, 2016.

LOPES, Y.; FERNANDES, N. C.; MUCHALUAT-SAADE, D. C. Geração distribuída de

energia: Desafios e perspectivas em redes de comunicação. **Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos**, v. 33, p. 40, 2015.

LÓPEZ, E. et al. On the potential of silicon intermediate band solar cells. **Energies**, v. 13, n. 12, p. 3044, 2020.

MA, H. et al. Multi-objective biogeography-based optimization for dynamic economic emission load dispatch considering plug-in electric vehicles charging. **Energy**, v. 135, p. 101–111, 2017.

MA, X.; HOVY, E. End-to-end sequence labeling via bi-directional lstm-cnns-crf. **arXiv preprint arXiv:1603.01354**, 2016.

MA, X.; WANG, Y.; WANG, C. Low-carbon development of China's thermal power industry based on an international comparison: Review, analysis and forecast. **Renewable and Sustainable Energy Reviews**, v. 80, p. 942–970, 2017.

MAFARJA, M. et al. Dragonfly algorithm: theory, literature review, and application in feature selection. **Nature-inspired optimizers**, p. 47–67, 2020.

MAGNANTI, T. L.; ORLIN, J. B. Network Flows. **PHI Englewood Cliffs NJ**, 1993.

MALIK, M. Z. et al. Strategic planning of renewable distributed generation in radial distribution system using advanced MOPSO method. **Energy Reports**, v. 6, p. 2872–2886, 2020.

MANDAL, K. K. et al. Non-convex emission constrained economic dispatch using a new self-adaptive particle swarm optimization technique. **Applied Soft Computing**, v. 28, p. 188–195, 2015.

MARIAKUTTIKAN, A. et al. Multi-objective economic dispatch of distributed generation using differential evolution algorithm. **IOP Conference Series: Materials Science and Engineering**, v. 1084, n. 1, p. 012016, mar. 2021.

MASINDI, V.; MUEDI, K. L. Environmental contamination by heavy metals. **Heavy metals**, v. 10, p. 115–132, 2018.

MIRANDA, V.; HANG, P. S. Economic dispatch model with fuzzy wind constraints and attitudes of dispatchers. **IEEE Transactions on power systems**, v. 20, n. 4, p. 2143–2145, 2005.

MIRJALILI, S. The ant lion optimizer. **Advances in engineering software**, v. 83, p. 80–98, 2015.

MIRJALILI, S. Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems. **Neural Computing and Applications**, v. 27, n. 4, p. 1053–1073, 2016.

MIRJALILI, S.; JANGIR, P.; SAREMI, S. Multi-objective ant lion optimizer: a multi-objective optimization algorithm for solving engineering problems. **Applied Intelligence**, v. 46, n. 1, p. 79–95, 2017.

MIRZENDEHDEL, A. M.; SURESH, K. A Pareto-optimal approach to multimaterial topology optimization. **Journal of Mechanical Design**, v. 137, n. 10, 2015.

MOHAMMED, A. S.; MURPHY, G. V.; NDOYE, M. **A PSO Based Control Strategy for Combined Emission Economic Dispatch with Integrated Renewables**. 2020 52nd North American Power Symposium (NAPS). **Anais...** Em: 2020 52ND NORTH AMERICAN POWER SYMPOSIUM (NAPS). abr. 2021.

MOHAMMED, A. Y.; MOHAMMED, F. I.; IBRAHIM, M. Y. **Grid connected Photovoltaic system**. 2017 International Conference on Communication, Control, Computing and Electronics Engineering (ICCCCEE). **Anais...IEEE**, 2017.

MORADI, B. The new optimization algorithm for the vehicle routing problem with time windows using multi-objective discrete learnable evolution model. **Soft Computing**, v. 24, n. 9, p. 6741–6769, 2020.

MURATA, T.; ISHIBUCHI, H.; TANAKA, H. Multi-objective genetic algorithm and its applications to flowshop scheduling. **Computers & industrial engineering**, v. 30, n. 4, p. 957–968, 1996.

MUSTAFA-MORAES, N. et al. The emission index as a parameter for assessing the environmental pollution from thermal power plants. Case study. **Dyna**, v. 83, n. 199, p. 218–224, 2016.

NASCIMENTO, M. H. R. et al. New solution for resolution of the economic load dispatch by different mathematical optimization methods, turning off the less efficient generators. **Journal of Engineering and Tecnology for Industrial Applications**, v. 3, p. 10, 2017a.

NASCIMENTO, M. H. R. et al. A new solution to the economical load dispatch of power plants and optimization using differential evolution. **Electrical Engineering**, v. 99, n. 2, p. 561–571, 2017b.

NWULU, N. I.; XIA, X. Multi-objective dynamic economic emission dispatch of electric power generation integrated with game theory based demand response programs. **Energy Conversion and Management**, v. 89, p. 963–974, 2015.

OPARA, K. R.; ARABAS, J. Differential Evolution: A survey of theoretical analyses. **Swarm and Evolutionary Computation**, v. 44, p. 546–558, 1 fev. 2019.

OPIYO, N. N. A comparison of DC-versus AC-based minigrids for cost-effective electrification of rural developing communities. **Energy Reports**, v. 5, p. 398–408, 2019.

PARNCUTT, R. et al. Live-streaming at international academic conferences: Technical and organizational options for single-and multiple-location formats. **Elementa: Science of the Anthropocene**, v. 7, 2019.

PILKO, H.; MANDŽUKA, S.; BARIĆ, D. Urban single-lane roundabouts: A new analytical approach using multi-criteria and simultaneous multi-objective optimization of geometry design, efficiency and safety. **Transportation Research Part C: Emerging Technologies**, v. 80, p. 257–271, 2017.

“**Previsão do tempo local, notícias e condições...** - Google Acadêmico. Disponível em: <https://scholar.google.com/scholar?hl=pt-BR&as_sdt=0%2C5&q=%E2%80%9CPrevis%C3%A3o+do+tempo+local%2C+not%C3%A0+Dcias+e+condi%C3%A7%C3%B5es+%7C+Clima+subterr%C3%A2neo%E2%80%9D.+http+s%3A%2F%2Fwww.wunderground.com%2F%3Fcm_ven%3Dcgi+%28acessado+mar.+24%2C+2020%29.&btnG=>>. Acesso em: 14 maio. 2021.

QIN, H. et al. An effective hybrid discrete grey wolf optimizer for the casting production scheduling problem with multi-objective and multi-constraint. **Computers & Industrial Engineering**, v. 128, p. 458–476, 2019.

QIN, Q. et al. Solving non-convex/non-smooth economic load dispatch problems via an enhanced particle swarm optimization. **Applied Soft Computing**, v. 59, p. 229–242, 2017.

RAHMAN, C. M.; RASHID, T. A. Dragonfly algorithm and its applications in applied science survey. **Computational Intelligence and Neuroscience**, v. 2019, 2019.

RAJASOMASHEKAR, S.; ARAVINDHABABU, P. Biogeography based optimization technique for best compromise solution of economic emission dispatch. **Swarm and evolutionary computation**, v. 7, p. 47–57, 2012.

RAJU, M.; SAIKIA, L. C.; SINHA, N. Automatic generation control of a multi-area system using ant lion optimizer algorithm based PID plus second order derivative controller. **International Journal of Electrical Power & Energy Systems**, v. 80, p. 52–63, 2016.

RAO, R. V.; RAI, D. P.; BALIC, J. A multi-objective algorithm for optimization of modern machining processes. **Engineering Applications of Artificial Intelligence**, v. 61, p. 103–125, 2017.

RAUNIYAR, A.; NATH, R.; MUHURI, P. K. Multi-factorial evolutionary algorithm based novel solution approach for multi-objective pollution-routing problem. **Computers & Industrial Engineering**, v. 130, p. 757–771, 2019.

REFAI, A.; EBEED, M.; KAMEL, S. **Combined Economic and Emission Dispatch Analysis Using Lightning Attachment Procedure Optimizer**. 2019 21st International Middle East Power Systems Conference (MEPCON). **Anais...** Em: 2019 21ST INTERNATIONAL MIDDLE EAST POWER SYSTEMS CONFERENCE (MEPCON). dez. 2019.

REN21. **REN21 - Building the sustainable energy future with renewable energy**. Disponível em: <<https://www.ren21.net/>>. Acesso em: 22 jun. 2021.

REYNOLDS, C. W. **Flocks, herds and schools: A distributed behavioral model**. Proceedings of the 14th annual conference on Computer graphics and interactive techniques. **Anais...**1987.

RHODES, J. D. et al. A geographically resolved method to estimate levelized power plant costs with environmental externalities. **Energy Policy**, v. 102, p. 491–499, 2017.

ROY, P. K.; BHUI, S. A multi-objective hybrid evolutionary algorithm for dynamic economic emission load dispatch. **International Transactions on Electrical Energy Systems**, v. 26, n. 1, p. 49–78, 2016.

SADOUDI, S.; BOUDOUR, M.; KOUBA, N. E. Y. **Optimal Combined Dynamic Economic and Emission Dispatch Including Wind and Photovoltaic Power Systems**. 2018 International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM). **Anais...** Em: 2018 INTERNATIONAL CONFERENCE ON ELECTRICAL SCIENCES AND TECHNOLOGIES IN MAGHREB (CISTEM). out. 2018.

SAITOV, E. B. et al. **Networked interactive solar panels over the roof photovoltaic system (PVS) and its cost analysis at Tashkent state technical University**. E3S Web of Conferences. **Anais...**EDP Sciences, 2020.

SAMPAIO, P. G. V.; GONZÁLEZ, M. O. A. Photovoltaic solar energy: Conceptual framework. **Renewable and Sustainable Energy Reviews**, v. 74, p. 590–601, 2017.

SANTANA, J. C. S. et al. O USO E PRODUÇÃO DA ENERGIA LIMPA COMO MÉTODO DE PRESERVAÇÃO AMBIENTAL SUSTENTÁVEL. **Epitaya E-books**, v. 1, n. 12, p. 99–111, 2 dez. 2020.

SAYAH, S.; HAMOUDA, A.; BEKRAR, A. Efficient hybrid optimization approach for emission constrained economic dispatch with nonsmooth cost curves. **International Journal of Electrical Power & Energy Systems**, v. 56, p. 127–139, 2014.

SERAFINI. Simulated annealing for multiple objective optimization problems, in volume 1 of the Proceedings of the Tenth International Conference on Multiple Criteria Decision Making, Taipei, pp. 87–96 (1992). 1992.

SHAHEEN, S.; COHEN, A. Shared micromobility policy toolkit: Docked and dockless bike and scooter sharing. 2019.

SHEKHAR, A. et al. Grid capacity and efficiency enhancement by operating medium voltage AC cables as DC links with modular multilevel converters. **International Journal of Electrical Power & Energy Systems**, v. 93, p. 479–493, 2017.

SHETA, A. et al. Nature-inspired metaheuristics search algorithms for solving the economic load dispatch problem of power system: a comparison study. Em: **Applied nature-inspired computing: algorithms and case studies**. [s.l.] Springer, 2020. p. 199–230.

SINGH, K. Business innovation and diffusion of off-grid solar technologies in India. **Energy for sustainable development**, v. 30, p. 1–13, 2016.

SRINIVAS N., K. DEB. **Multi-objective optimization using non-dominated sorting in genetic algorithms**, **Evolutionary Computation 2**, pp. 221–248 (1994).

STORN, R.; PRICE, K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. **Journal of global optimization**, v. 11, n. 4, p. 341–359, 1997.

STRUB, O.; BAUMANN, P. Optimal construction and rebalancing of index-tracking portfolios. **European journal of operational research**, v. 264, n. 1, p. 370–387, 2018.

SUN, S. et al. Multi-Objective Optimal Dispatching for a Grid-Connected Micro-Grid Considering Wind Power Forecasting Probability. **IEEE Access**, v. 8, p. 46981–46997, 2020.

SUPPAPITNARM, A. et al. **Design by multiobjective optimisation using simulated annealing**. Proceedings of the 12th International Conference on Engineering Design, ICED'99. **Anais...** Technische Universitat Munchen, 1999.

SURESH, V.; SREEJITH, S. Generation dispatch of combined solar thermal systems using dragonfly algorithm. **Computing**, v. 99, n. 1, p. 59–80, 2017.

TALAQ, J. H.; EL-HAWARY, F.; EL-HAWARY, M. E. A summary of environmental/economic dispatch algorithms. **IEEE Transactions on Power Systems**, v. 9, n. 3, p. 1508–1516, 1994.

TAMAKI, H.; KITA, H.; KOBAYASHI, S. **Multi-objective optimization by genetic algorithms: A review**. Proceedings of IEEE international conference on evolutionary computation. **Anais...IEEE**, 1996.

T'KINDT, V.; BILLAUT, J.-C. **Multicriteria scheduling: theory, models and algorithms**. [s.l.] Springer Science & Business Media, 2006.

TORRES, P. F. et al. A mobile educational tool designed for teaching and dissemination of grid connected photovoltaic systems. **Computers & Electrical Engineering**, v. 76, p. 168–182, 2019.

TRIVEDI, I. N.; JANGIR, P.; PARMAR, S. A. Optimal power flow with enhancement of voltage stability and reduction of power loss using ant-lion optimizer. **Cogent engineering**, v. 3, n. 1, p. 1208942, 2016.

TURGUT, M. S.; DEMIR, G. K. Quadratic approximation–based hybrid Artificial Cooperative Search algorithm for economic emission load dispatch problems. **International Transactions on Electrical Energy Systems**, v. 27, n. 4, p. e2284, 2017.

ULUNGU, E. L. et al. MOSA method: a tool for solving multiobjective combinatorial optimization problems. **Journal of multicriteria decision analysis**, v. 8, n. 4, p. 221, 1999.

VARGAS, M. C.; MENDES, M. A.; BATISTA, O. E. **Impacts of high pv penetration on voltage profile of distribution feeders under brazilian electricity regulation**. 2018 13th IEEE International Conference on Industry Applications (INDUSCON). **Anais...IEEE**, 2018.

VILLALVA, M. G. Conversor eletrônico de potência trifásico para sistema fotovoltaico conectado à rede elétrica. 2010.

WANG, L.; SINGH, C. Environmental/economic power dispatch using a fuzzified multi-objective particle swarm optimization algorithm. **Electric Power Systems Research**, v. 77, n. 12, p. 1654–1664, 2007.

WATSON, S. et al. Advantages of operation flexibility and load sizing for PV-powered system design. **Solar Energy**, v. 162, p. 132–139, 2018.

WIECEK, M. M.; EHRGOTT, M.; ENGAU, A. Continuous multiobjective programming. Em: **Multiple Criteria Decision Analysis**. [s.l.] Springer, 2016. p. 739–815.

WU, Y.; ZHAO, B.; LIU, L. **Solving economic load dispatch problem with valve point effect using mean guiding differential evolution**. IECON 2017 - 43rd Annual Conference of the

IEEE Industrial Electronics Society. **Anais...** Em: IECON 2017 - 43RD ANNUAL CONFERENCE OF THE IEEE INDUSTRIAL ELECTRONICS SOCIETY. out. 2017.

YAO, P.; WANG, H. Dynamic Adaptive Ant Lion Optimizer applied to route planning for unmanned aerial vehicle. **Soft Computing**, v. 21, n. 18, p. 5475–5488, 2017.

ZEYNALI, S.; ROSTAMI, N.; FEYZI, M. R. Multi-objective optimal short-term planning of renewable distributed generations and capacitor banks in power system considering different uncertainties including plug-in electric vehicles. **International Journal of Electrical Power & Energy Systems**, v. 119, p. 105885, 2020.

ZHAN, Z.-H. et al. Adaptive Distributed Differential Evolution. **IEEE Transactions on Cybernetics**, v. 50, n. 11, p. 4633–4647, nov. 2020.

ZHANG, B. et al. The indecisive role of the market in China's SO₂ and COD emissions trading. **Environmental Politics**, v. 25, n. 5, p. 875–898, 2016.

ZHENG, M. et al. Economic and environmental benefits of coordinating dispatch among distributed electricity storage. **Applied energy**, v. 210, p. 842–855, 2018.

ZHU, J. **Optimization of power system operation**. [s.l.] John Wiley & Sons, 2015.

ZITZLER, E.; LAUMANNNS, M.; BLEULER, S. A tutorial on evolutionary multiobjective optimization. **Metaheuristics for multiobjective optimisation**, p. 3–37, 2004.