

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
INSTITUTO DE COMPUTAÇÃO
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

RONALD ALBERT DE ARAÚJO JÚNIOR

Técnicas de computação evolutiva para problemas multi-objetivo aplicadas à geração de energia elétrica de fonte renovável.

RIO DE JANEIRO
2023

RONALD ALBERT DE ARAÚJO JÚNIOR

Técnicas de computação evolutiva para problemas multi-objetivo aplicadas à geração de energia elétrica de fonte renovável.

Trabalho de conclusão de curso de graduação apresentado ao Instituto de Computação da Universidade Federal do Rio de Janeiro como parte dos requisitos para obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Profa. Carla Amor Divino Moreira Delgado
Co-orientador: Profa. Carolina Gil Marcelino

RIO DE JANEIRO

2023

CIP - Catalogação na Publicação

A663t Araújo Júnior, Ronald Albert de
Técnicas de computação evolutiva para problemas multi-objetivo aplicadas à geração de energia elétrica de fonte renovável / Ronald Albert de Araújo Júnior. -- Rio de Janeiro, 2023.
54 f.

Orientadora: Carla Amor Divino Moreira Delgado.
Coorientadora: Carolina Gil Marcelino.
Trabalho de conclusão de curso (graduação) -
Universidade Federal do Rio de Janeiro, Instituto de Computação, Bacharel em Ciência da Computação, 2023.

1. Otimização multiobjetivo. 2. Modelagem matemática. 3. Computação evolutiva. I. Delgado, Carla Amor Divino Moreira, orient. II. Marcelino, Carolina Gil, coorient. III. Título.

RONALD ALBERT DE ARAÚJO JÚNIOR

Técnicas de computação evolutiva para problemas multi-objetivo aplicadas à geração de energia elétrica de fonte renovável.

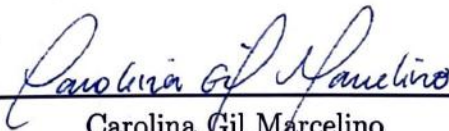
Trabalho de conclusão de curso de graduação apresentado ao Instituto de Computação da Universidade Federal do Rio de Janeiro como parte dos requisitos para obtenção do grau de Bacharel em Ciência da Computação.

Aprovado em 24 de abril de 2023

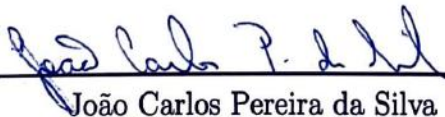
BANCA EXAMINADORA:



Carla Amor Divino Moreira Delgado
D.Sc (UFRJ)



Carolina Gil Marcelino
D.Sc (CEFET-MG)



João Carlos Pereira da Silva
D.Sc (UFRJ)



Elizabeth Fialho Wanner, D.Sc (UFMG)

AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq, órgão associado ao Ministério da Ciência e Tecnologia, pela bolsa fornecida, na modalidade ITC no período de o período de 01/03/2022 a 31/12/2022, para o desenvolvimento deste trabalho.

Às minhas orientadoras Carolina Gil Marcelino e Carla Amor, por toda a orientação e auxílio, essenciais para a conclusão deste trabalho.

Ao grupo de otimização evolutiva da Universidade Federal do Rio de Janeiro, não só pelo auxílio no entendimento do métodos implementados, como pela companhia e amizade construídos ao longo do desenvolvimento.

Aos meus pais, Ronald Albert e Carla Bitencourt que sempre me apoiaram e estiveram ao meu lado durante toda minha formação.

Ao meu avô, Francisco de Assis, que foi essencial para a conclusão desta graduação.

A minha irmã, Rebecca Bitencourt, pelo apoio e boas risadas.

A todos meu muito obrigado.

RESUMO

A maior parte da energia elétrica brasileira é proveniente de fonte renovável via usinas hidrelétricas. O funcionamento de tais usinas pode ser modelado como um problema de otimização multi-objetivo, tal que sejam maximizados a geração de energia, o nível de água nos reservatórios e de forma que o fluxo de água seja minimamente alterado após o processo de otimização. Neste contexto, o trabalho se propõe a estudar o desempenho de diferentes meta-heurísticas evolutivas aplicadas ao problema de despacho elétrico em usinas em modo cascata (ao menos duas plantas no leito de um rio). Meta-heurísticas evolutivas tem como base para a busca de soluções otimizadas operadores inspirados em mecanismos da natureza, como: seleção natural, recombinação e mutação. O trabalho tem foco especial no algoritmo *Multi-objective Evolutionary Swarm Hybridization* - MESH, proposto em (OLIVEIRA, 2019) no qual foi aplicado a problemas com dois objetivos conflitantes. Experimentos preliminares no decorrer deste trabalho indicam que o MESH se mostra competitivo quando comparado à meta-heurísticas evolutivas *standard*: o *Multiobjective Evolutionary Algorithm Based on Decomposition* - MOEA/D (ZHANG; LI, 2007) e versões de *Non-dominated Sorting Genetic Algorithm* - NSGA (DEB et al., 2002a) e (DEB; JAIN, 2014). As simulações utilizaram um conjunto de problemas de *benchmark* conhecido, levando em conta três objetivos conflitantes. Além disso, o algoritmo estudado apresenta resultados relevantes na solução do problema do despacho elétrico em um cenário generalista de usinas hidrelétricas em cascata.

Palavras-chave: Inteligência Artificial; Otimização Multiobjetivo; Otimização Heurística; Usina hidrelétrica; Eficiência Energética

ABSTRACT

Most of Brazil's electricity comes from renewable sources through hydroelectric power plants. The operation of these plants can be modeled as a multi-objective optimization problem, in which the generation of energy, the water level in the reservoirs, and the minimal alteration of water flow after the optimization process are maximized. In this context, the work proposes to study the performance of different evolutionary meta-heuristics applied to the problem of electric dispatch in cascade mode power plants (at least two plants on a riverbed). Evolutionary meta-heuristics are based on operators inspired by natural mechanisms, such as natural selection, recombination, and mutation. The work has a special focus on the Multi-Objective Evolutionary Swarm Hybridization (MESH) algorithm, proposed in (OLIVEIRA, 2019), which has been applied to problems with two conflicting objectives. Preliminary experiments in this work indicate that MESH is competitive when compared to standard evolutionary meta-heuristics: the Multi-Objective Evolutionary Algorithm Based on Decomposition (MOEA/D) (ZHANG; LI, 2007) and versions of Non-dominated Sorting Genetic Algorithm (NSGA) (DEB et al., 2002a) and (DEB; JAIN, 2014). The simulations used a set of known benchmark problems, taking into account three conflicting objectives. In addition, the studied algorithm presents relevant results in solving the electric dispatch problem in a general scenario of cascade hydroelectric power plants.

Keywords: Artificial Intelligence; Multi-Objective Optimization; Heuristic Optimization; Hydroelectric Power Plant; Energy Efficiency

LISTA DE ILUSTRAÇÕES

Figura 1 – Gráfico da energia gerada no Brasil em GWh para o ano de 2022	14
Figura 2 – Fronteira de Pareto em um espaço objetivo bidimensional	18
Figura 3 – A movimentação de uma partícula no algoritmo PSO	20
Figura 4 – O processo de atualização do arquivo de memória do MESH usando o operado de distância de multidões	22
Figura 5 – Principais componentes de uma UHE	25
Figura 6 – Ilustração da medida de hipervolume para um problema biobjetivo	30
Figura 7 – Gráfico da fronteira de Pareto do problema teste DTLZ 1	32
Figura 8 – Gráfico da fronteira de Pareto do problema teste DTLZ 2	33
Figura 9 – Gráfico da fronteira de Pareto do problema teste DTLZ 3	34
Figura 10 – Gráfico da fronteira de Pareto do problema teste DTLZ 5	35
Figura 11 – Gráfico da fronteira de Pareto do problema teste DTLZ 6	36
Figura 12 – Gráfico da fronteira de Pareto do problema teste DTLZ 7	37
Figura 13 – Gráfico da fronteiras Pareto Combinadas do problema teste DTLZ	39
Figura 14 – Diagrama para o processo de otimização da Usina Hidrelétrica	42
Figura 15 – Gráfico da fronteiras Pareto Combinadas para as horas de 0 a 8	46
Figura 16 – Gráfico da fronteiras Pareto Combinadas para as horas de 9 a 17	47
Figura 17 – Gráfico da fronteiras Pareto Combinadas para as horas de 18 a 23	48

LISTA DE TABELAS

Tabela 1 – Coeficientes Operativos	27
Tabela 2 – Coeficientes dos polinômios da cota montante e da cota jusante	43
Tabela 3 – Vazões Afluentes de cada UHE por hora	43
Tabela 4 – Demanda energética de cada UHE por hora	44
Tabela 5 – Vazões no modelo de controle conjunto de cada UHE por hora	44

LISTA DE QUADROS

Quadro 1	– Média dos resultados para o hipervolumes de cada um dos algoritmos	40
Quadro 2	– Desvios Padrão dos resultados para o hipervolumes de cada um dos algoritmos	40
Quadro 3	– p-valores para o Teste U de Mann-Whitney	41
Quadro 4	– Média dos resultados para o hipervolumes de cada um dos algoritmos	49
Quadro 5	– Desvio Padrão dos resultados para o hipervolumes de cada um dos algoritmos	50
Quadro 6	– P-valores para o Teste U de Mann-Whitney	51

LISTA DE ABREVIATURAS E SIGLAS

DE	<i>Differential Evolution</i>
PSO	<i>Particle Swarm Optimization</i>
C-DEEPSO	<i>Canonical Differential Evolutionary Particle Swarm Optimization</i>
MESH	<i>Multi-objective Evolutionary Swarm Hybridization</i>
NSGA	<i>Non-dominated Sorting Genetic Algorithm</i>
MOEA/D	<i>A Multiobjective Evolutionary Algorithm Based on Decomposition</i>
SCD	<i>Special Crowding Distance</i>
UHE	Usina Hidrelétrica
c. c.	Caso contrário

LISTA DE SÍMBOLOS

\mathbb{R}	Conjunto dos números reais
$f : \Omega \rightarrow \Lambda$	Função f com domínio em Ω e contra-domínio em Λ
$\forall x$	Para toda variável x
\in	Pertence
\mathbb{R}^n	Espaço euclidiano de dimensão n .
\mathcal{X}_P	Conjunto de soluções ótimas
$\partial\mathcal{F}$	Fronteira de Pareto

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OTIMIZAÇÃO MULTI-OBJETIVO	13
1.2	CONTEXTO ENERGÉTICO BRASILEIRO	14
1.3	OBJETIVOS	15
1.4	ORGANIZAÇÃO DO TRABALHO	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	OTIMIZAÇÃO MONO-OBJETIVO	16
2.2	OTIMIZAÇÃO MULTIOBJETIVO	16
2.2.1	Formulação	16
2.2.2	Relações de Dominância	17
2.2.3	Pareto-Optimalidade	17
2.3	COMPUTAÇÃO EVOLUTIVA	18
2.3.1	Evolução Diferencial (DE)	18
2.3.2	Otimização Por Enxame de Partículas (PSO)	20
2.3.3	Multi-objective Evolutionary Swarm Hybridization (MESH)	21
2.3.3.1	SCD - Distância de Multidões Especial	23
2.4	USINA HIDRELÉTRICA	24
2.4.1	Principais Componentes de uma UHE	24
2.4.2	Balanco Hídrico De Um Reservatório De Uma UHE	25
2.4.3	Modelo Matemático da Operação de UHEs em cascata	26
3	METODOLOGIA	30
3.1	MEDIDA DE HIPERVOLUME (HV)	30
3.2	TESTE ESTATÍSTICOS - TESTE U DE MANN-WHITNEY	31
3.3	PARETO COMBINADO	31
3.4	PROBLEMAS DE <i>BENCHMARK</i>	31
3.4.1	DTLZ	32
3.4.1.1	DTLZ 1	32
3.4.1.2	DTLZ 2	33
3.4.1.3	DTLZ 3	33
3.4.1.4	DTLZ 5	34
3.4.1.5	DTLZ 6	35
3.4.1.6	DTLZ 7	36
4	RESULTADOS	38

4.1	DTLZ	38
4.1.1	Soluções Pareto Combinadas	38
4.1.2	Análise Estatística dos Resultados	39
4.1.3	Observações Finais	40
4.2	MODELO DA USINA HIDRELÉTRICA EM CASCATA	41
4.2.1	Descrição do sistemas de UHE's em cascata	42
4.2.2	Soluções Pareto Combinadas	44
4.2.3	Análise Estatística dos Resultados	49
4.2.4	Observações Finais	51
5	CONCLUSÃO	52
	REFERÊNCIAS	53

1 INTRODUÇÃO

Problemas de otimização consistem em encontrar a melhor combinação de variáveis para se minimizar uma função, geralmente chamada de função objetivo (IZMAILOV, 2020). Existem duas principais abordagens para a resolução de problemas de otimização, são elas por métodos determinísticos ou por meta-heurísticas.

A classe de métodos determinísticos garante convergência para o ótimo global da função objetivo em tempo finito. Tais métodos se sustentam por garantias matemáticas teóricas de que a solução encontrada é, de fato, o ótimo global. Enquanto na abordagem meta-heurística não existe garantia de que a solução encontrada é o ótimo global. As meta-heurísticas baseiam-se em buscas pela solução do problema no espaço seguindo determinada orientação (TAKAHASHI, 2012).

A otimização heurística (otimização por meta-heurísticas) geralmente é empregada em contextos onde o problema de otimização é tão complexo que a solução por métodos determinísticos não pode ser encontrada ou tem alto custo computacional, levando um tempo intratável para ser encontrada.

Uma classe especial de meta-heurísticas, são os métodos de computação evolutiva, que se inspiram nos mecanismos de adaptação dos seres da natureza para construção da orientação que a busca pela solução do problema vai seguir. Diferentes mecanismos inspirados em dinâmicas biológicas são empregados nas heurísticas para a construção desses métodos, sendo alguns deles: seleção natural, comportamento de colônias de formigas, etc. Esse trabalho trata exclusivamente de métodos inspirados na computação evolutiva.

1.1 OTIMIZAÇÃO MULTI-OBJETIVO

O principal foco deste trabalho está na otimização multi-objetivo, campo da otimização que busca por soluções que minimizem duas ou mais funções objetivo (COLLETTE, 2004). Em contextos multi-objetivo, os algoritmos não buscam por uma única solução, mas sim por um conjunto de soluções que sejam capazes, de minimizar todas as funções objetivo simultaneamente.

Assim como nos problemas de otimização tradicionais, na abordagem de solução de problemas multi-objetivo existem métodos determinísticos e estocásticos. Neste contexto, uma classe muito estudada de métodos heurísticos são os algoritmos evolutivos.(DEB; KALYANMOY, 2001).

Neste trabalho, o desempenho do algoritmo Multi-objective Evolutionary Swarm Hybridization (MESH), proposto em (OLIVEIRA, 2019) é avaliado em problemas com 3 funções objetivo. O seu desempenho foi comparado frente a outros métodos de computação evolutiva bem estabelecidos no campo de otimização. A análise de desempenho dos

algoritmos é realizada em problemas sintéticos para teste, como em um problema real do despacho elétrico de usinas hidrelétricas em cascata.


Além disso, uma nova configuração para o algoritmo MESH, também foi empregada, que diz respeito ao seu operador de distância de multidões, o qual confere uma maior distribuição das soluções. A nova configuração, proposta em (YUE et al., 2021), é empregada no MESH e comparada com o operador de distância de multidões original do algoritmo.

1.2 CONTEXTO ENERGÉTICO BRASILEIRO

A geração de energia no Brasil é oriunda, majoritariamente, de fontes renováveis de energia, sendo a sua grande maioria fontes hidráulicas (ONS, 2022). Conforme percebido na Figura 1 a geração por parte das usinas hidrelétricas compõem 72% de toda a energia gerada no Brasil.

Grande parte das usinas hidrelétricas brasileiras operam em um sistema de controle conjunto, onde a distribuição da fonte hidráulica é igualitária para todas as unidades geradoras. Abordagens mais recentes, sugerem que é possível otimizar a operação sobre diferentes óticas quando empregadas distintas distribuições para cada unidade geradora. Em muitas de tais abordagens, a utilização de algoritmos evolutivos se faz presente para a otimização da operação da usina hidrelétrica (LANSBERRY; WOZNIAK; GOLDBERG, 1992) (LANSBERRY; WOZNIAK, 1994).

Figura 1 – Gráfico da energia gerada no Brasil em GWh para o ano de 2022



Retirado do website (ONS, 2022)

Como aplicação prática para os algoritmos estudados neste trabalho, um modelo pro-

posto em (OLIVEIRA, 2019) e (MARCELINO et al., 2021), de operação de usina hidrelétrica em cascata é ampliado com a adição de um terceiro objetivo. Tal modelo é multi-objetivo, o que significa que visa otimizar a geração de energia da usina, enquanto mantém altos os volumes de água no reservatório da usina e não modifica completamente a maneira como a usina originalmente opera.

1.3 OBJETIVOS

1. Avaliação do desempenho do algoritmo MESH em problemas com 3 funções objetivos e comparação com outros métodos bem estabelecidos.
2. Implementação do novo operador de distância de multidões para o algoritmo MESH e avaliação do mesmo em comparação com a distância de multidões original do MESH.
3. Aplicação dos métodos evolutivos em um problema prático de otimização da operação de uma usina hidrelétrica em cascata.
4. Inclusão de um terceiro objetivo na modelagem de usina em cascata. Este objetivo indica a distância entre a operação de controle conjunto e o controle otimizado.

1.4 ORGANIZAÇÃO DO TRABALHO

Todo o texto está dividido em 5 capítulos, sendo o primeiro deles a corrente introdução. O segundo capítulo diz respeito a fundamentação teórica, necessária para a compreensão dos experimentos realizados. Nele são apresentados os principais conceitos de otimização multi-objetivo, assim como, as heurísticas que norteiam os algoritmos evolutivos implementados. No segundo capítulo, também é descrito o modelo matemático para a operação da usina hidrelétrica em cascata.

No terceiro capítulo é descrita a metodologia que será seguida pelos experimentos realizados: são apresentadas as métricas de avaliação de solução para problemas multi-objetivo e os problemas de teste implementados. No quarto capítulo são apresentados os resultados obtidos em cada experimento, assim como, a comparação de desempenho entre cada um dos algoritmos. O quinto capítulo discute as conclusões do corrente trabalho e propõe futuros caminhos para o trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 OTIMIZAÇÃO MONO-OBJETIVO

Dados os conjunto D , Ω e uma função $f : \Omega \rightarrow \mathbb{R}$, tal que $D \subseteq \Omega$.

O problema de otimização diz respeito a encontrar o ponto minimizador de f em D . Tal problema é comumente escrito como:

$$\begin{aligned} \min \quad & f(x) \\ \text{sujeito a} \quad & x \in D \end{aligned}$$

Em outras palavras, encontrar o ponto minimizador significa encontrar o elemento $\bar{x} \in D$, tal que

$$f(\bar{x}) \leq f(x) \quad \forall x \in D$$

Em determinados problemas, o conjunto D pode ser escrito por meio de restrições de igualdade e desigualdade. Dessa forma, para tais problemas, é possível reformular o problema de otimização proposto anteriormente:

$$\begin{aligned} \min \quad & f(x) \\ \text{s.a.} \quad & h(x) = 0 \\ & g(x) \leq 0 \end{aligned}$$

onde $h : \Omega \rightarrow \mathbb{R}^l$ e $g : \Omega \rightarrow \mathbb{R}^m$, e l e m são as quantidades de restrições de igualdade e desigualdade, respectivamente.

Se, caso o interesse estivesse em encontrar o máximo de $f(x)$, é fácil perceber que bastaria uma pequena modificação na formulação, trocando a função objetivo $f(x)$ por $-f(x)$, assim fica evidente que os problemas de maximização e minimização são análogos. Para uma abordagem mais aprofundada do tema otimização matemática, temos (MACULAN, 2004), (IZMAILOV, 2020).

2.2 OTIMIZAÇÃO MULTI-OBJETIVO

2.2.1 Formulação

Na formulação tradicional de problemas de otimização, temos uma única função objetivo. No entanto, é possível que haja o interesse de se otimizar mais de uma função objetivo simultaneamente, em tais casos, nos deparamos com um problema de otimização multiobjetivo.

Dados os conjunto D , Ω e funções $f_i : \Omega \rightarrow \mathbb{R}, i = 1, 2, \dots, n$, tal que $D \subseteq \Omega$, os problemas

de otimização multiobjetivo são formulados da seguinte forma:

$$\begin{aligned} \min \quad & f_1(x) \\ & f_2(x) \\ & \dots \\ & f_n(x) \\ \text{sujeito a} \quad & x \in D \end{aligned}$$

É possível, também, formular o problema como uma única função objetivo $f : \Omega \rightarrow \mathbb{R}^n$. Para fins de terminologia, em problemas de otimização multiobjetivo costumeiramente, o conjunto Ω é chamado de espaço de decisão, enquanto o mapeamento da função $f(x)$ é conhecido como espaço objetivo \mathbb{R}^n .

2.2.2 Relações de Dominância

De acordo com (AUDET et al., 2021), no contexto de problemas multiobjetivo, temos as seguintes relações entre vetores do espaço de decisão:

Dados dois vetores x e x' no espaço de decisão Ω , e sendo $f_i(x), i = 1, 2, \dots, n$ as funções objetivo, definimos as seguintes relações:

1. $x \preceq x'$ (x' é fracamente dominado por x) se e somente se $\forall i f_i(x) \leq f_i(x')$
2. $x \prec x'$ (x' é dominado por x) se e somente se $x \preceq x' \wedge \exists i f_i(x) < f_i(x')$
3. $x \prec\prec x'$ (x' é estritamente dominado por x) se e somente se $\forall i f_i(x) < f_i(x')$
4. $x \parallel x'$ (x' e x são incomparáveis) é o caso em que nem x é fracamente dominado por x' , nem x' é fracamente dominado por x .

Com tais relações, é possível definir a solução (ou o conjunto de soluções) de um problema multiobjetivo.


2.2.3 Pareto-Otimalidade

O vetor x no espaço de decisão Ω é uma solução ótima de Pareto, se não existe outro vetor x' em Ω que domine x ($x' \prec x$). Usualmente, o conjunto de soluções ótimas de Pareto é chamado de *Conjunto de Pareto*, denotado por \mathcal{X}_P . O conjunto gerado pela aplicação da função objetivo no Conjunto de Pareto $f[\mathcal{X}_P]$, é chamado de *Fronteira de Pareto* e comumente denotado por $\partial\mathcal{F}$.

O conceito de Fronteira de Pareto surge em problemas multiobjetivo, devido a natureza de funções objetivo serem conflitantes. Diferente do caso de problemas mono-objetivo, onde temos uma única solução ótima, no contexto multiobjetivo, um vetor do espaço de decisão, geralmente, não é o minimizador de duas funções simultaneamente. Por isso

temos o interesse em várias soluções, ao invés de procurar uma única solução, como no contexto mono-objetivo.

Figura 2 – Fronteira de Pareto em um espaço objetivo bidimensional



Fonte: (DEB; KALYANMOY, 2001)

2.3 COMPUTAÇÃO EVOLUTIVA

A computação evolutiva é definida por uma classe de algoritmos de busca que inspiram as suas heurísticas em dinâmicas da evolução natural. No contexto de um algoritmo evolutivo, a cada iteração temos um conjunto de possíveis soluções, ao qual damos o nome de população, esses são atualizados a cada iteração, com a esperança de que a cada geração, a partir da população inicial, encontramos melhores valores para a função objetivo (TAKAHASHI, 2012).

Usualmente, empregamos a solução por algoritmos da computação evolutiva (e outros métodos não-determinísticos de otimização) quando a solução para o problema em questão leva um tempo intratável para ser encontrada por abordagens determinísticas. Neste trabalho o algoritmo MESH (Multi-objective Evolutionary Swarm Hybridization algorithm) de (MARCELINO et al., 2021) é utilizado. Tal método tem inspirações em operadores de algoritmos evolutivos mono objetivos; DE (*Differential Evolution*) (STORN; PRICE, 1997) e PSO (*Particle Swarm Optimization*) (KENNEDY; EBERHART, 1995). Além disso, o MESH, também faz uso do operador de distância de multidão do algoritmo NSGA-II (DEB et al., 2002a).

2.3.1 Evolução Diferencial (DE)

Proposto por (STORN; PRICE, 1997), o algoritmo de Evolução Diferencial (DE) se difere dos outros algoritmos no campo da computação evolutiva porque tal algoritmo não tem clara inspiração em algum mecanismo evolutivo da natureza. No entanto, o algoritmo

ainda apresenta os conceitos de população, e os operadores de mutação, recombinação e seleção.

A partir da população inicial, o algoritmo gera novos indivíduos por meio do operador de mutação diferencial. A ideia do operador é combinar a diferença entre dois indivíduos distintos com um terceiro indivíduo. Sendo P a população de indivíduos e $X_{r1}, X_{r2}, X_{r3} \in P$ indivíduos distintos, geramos o **vetor mutante** V de acordo com a Equação 2.1

$$V = X_{r1} + F \cdot (X_{r2} - X_{r3}) \quad (2.1)$$

onde $F \in [0, 1]$ é uma constante que controla a influência da diferença de $(X_{r2} - X_{r3})$. É interessante perceber que só é possível aplicar tal operador a indivíduos no espaço contínuo.

Dessa forma, é possível gerar uma população mutante MP , a partir da população original. É justamente tal população mutante que usaremos no operador de recombinação. A recombinação irá gerar uma nova população de indivíduos, chamada de indivíduos teste.

$$U_i = \begin{cases} V_i, & (rand \leq CR) \vee (i = \delta) \\ X_i & \text{c. c.} \end{cases}$$

onde $rand$ é uma realização de uma distribuição $U(0, 1)$, CR é o hiper-parâmetro de recombinação e δ é um índice aleatório dos vetores da população (o δ existe para garantir que, pelo menos, uma entrada do indivíduo sofrerá mutação).

O operador de recombinação é realizado, para cada um dos indivíduos da população corrente, assim gerando um indivíduo de teste para cada indivíduo.

Após esse procedimento, temos o operador de seleção, que simplesmente compara, de maneira gulosa, o indivíduo de teste com o seu respectivo indivíduo da população original, e seleciona aquele que confere um melhor resultado para a função objetivo. Dessa maneira, gerando a população da próxima iteração do algoritmo.

Além da formulação original do DE, existem variações que modificam um pouco os operados mencionados anteriormente. Para cada uma dessas formulações, temos a seguinte notação $DE/X/Y/Z$.

1. X diz respeito aos vetores escolhidos para a realização do operador de mutação, no caso original temos $X = rand$, uma vez que os vetores foram escolhidos aleatoriamente.
2. Y diz respeito ao números de vetores de diferença na diferença do operador de mutação, no caso da formulação original $Y = 1$.
3. Z determina como o operador de recombinação vai funcionar, no algoritmo original $Z = bin$ (Binomial), visto que a recombinação é gerada, a partir de experimentos Bernoulli independentes.

2.3.2 Otimização Por Enxame de Partículas (PSO)

Exposto em (KENNEDY; EBERHART, 1995), o Particle Swarm optimization (PSO), assim como o DE, é uma meta-heurística evolutiva de espaço de decisão contínuo. A sua inspiração tem origem nas dinâmicas sociais de movimentação de animais em bando.

No contexto do PSO, cada indivíduo da população P , é comumente chamado de Partícula. Sendo $X \in P$ uma partícula da população, a atualização deste indivíduo é realizada da seguinte forma:

$$X_i^{t+1} = X_i^t + V_i^t \quad (2.2)$$

Como podemos ver na Equação 2.2, determinada partícula é atualizada de acordo com V_i , a este damos o nome de vetor velocidade.

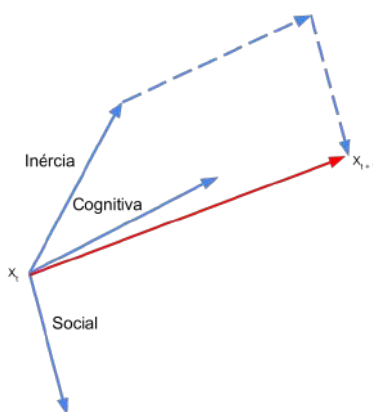
O vetor velocidade V_i é composto pela soma de 3 componentes; a primeira delas é o atual valor de V_i , a qual damos o nome de componente de **Inércia**, a segunda é a subtração do melhor valor encontrado em todo o histórico da partícula em questão pelo atual valor da partícula ($P_i^t - X_i^t$), a qual damos o nome de componente **Cognitiva**, a terceira é a subtração do melhor valor encontrado em todo o histórico da população pelo atual valor da partícula ($G^t - X_i^t$), a qual damos o nome de componente **Social**. Além disso, determinado peso w_j é atribuído a cada uma das componente.

$$V_i^{t+1} = w_1 \cdot V_i^t + w_2 \cdot (P_i^t - X_i^t) + w_3 \cdot (G^t - X_i^t) \quad (2.3)$$

Em determinadas implementações, é possível adicionar um fator aleatório $u_i \in [0, 1]$ a cada uma das componentes na equação 2.3:

$$V_i^{t+1} = u_1 \cdot w_1 \cdot V_i^t + u_2 \cdot w_2 \cdot (P_i^t - X_i^t) + u_3 \cdot w_3 \cdot (G^t - X_i^t)$$

Figura 3 – A movimentação de uma partícula no algoritmo PSO



Adaptado de (MIRANDA; FONSECA, 2002)

2.3.3 Multi-objective Evolutionary Swarm Hybridization (MESH)

Inspirado no algoritmo mono-objetivo C-DEEPSO proposto em (MARCELINO et al., 2018) e (MARCELINO et al., 2021). O algoritmo Multi-objective Evolutionary Swarm Hybridization (MESH) (OLIVEIRA, 2019) utiliza os mesmos operadores para atualização da população que a sua versão mono-objetivo, no entanto, incorpora um operador extra de *Crowding Distance* do algoritmo NSGA-II (DEB et al., 2002a).

Assim como no PSO, temos que o MESH é atualizado por um vetor V^t , chamado de vetor velocidade.

$$X_i^{t+1} = X_i^t + V_i^t$$

Onde, o vetor velocidade V_i^t , é construído da seguinte maneira:

$$V_i^{t+1} = w_I^* \cdot V_i^t + w_A^* \cdot (X_{sn}^t - X_i^t) + w_C^* \cdot C \cdot (X_{gb}^* - X_i^t) \quad (2.4)$$

A equação 2.4 é bastante similar a equação 2.3 que determina a atualização do vetor de velocidade no PSO com algumas diferenças pontuais.

A principal delas ocorre na componente **Cognitiva** $w_A^* \cdot (X_{sn}^t - X_i^t)$, onde X_{sn}^t é construído a partir do operador de mutação diferencial. Sendo X_{r1}, X_{r2}, X_{r3} indivíduos distintos da população, temos:

$$X_{sn} = X_{r1} + F \cdot (X_{r2} - X_{r3}) \quad (2.5)$$

Dependendo da estratégia adotada no *Differential Evolution*, podemos modificar levemente a equação 2.5.

Na equação 2.4, o super-escrito * indica que tal parâmetro passa por um processo de mutação estocástica da seguinte maneira:

$$w^* = w + \tau \cdot N(0, 1)$$

Onde $\tau \in [0, 1]$ é um dos hiper-parâmetros do algoritmo e $N(0, 1)$ é uma amostra de uma Distribuição Gaussiana Padrão. A mutação da variável X_{gb}^* , acontece para cada partícula, da seguinte maneira:

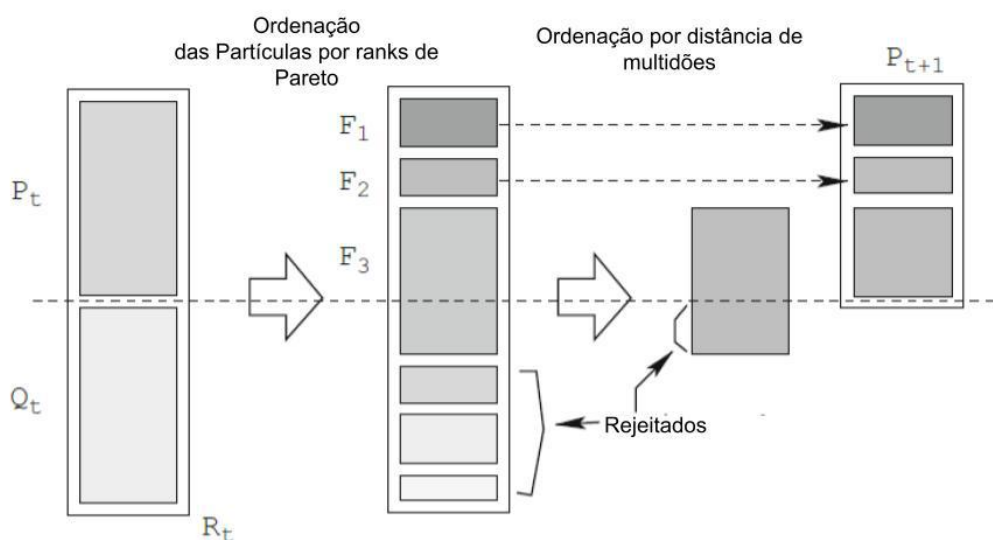
$$X_{gb}^* = X_{gb} \cdot (1 + \tau \cdot N(0, 1))$$

O algoritmo também mantém um arquivo, onde as melhores soluções, encontradas ao momento são armazenadas. A cada iteração, o conteúdo do arquivo é modificado de acordo com o operador de distância de multidões do algoritmo NSGA-II (DEB et al., 2002a).

O processo do operador de distância multidões se inicia por ordenar cada uma das partículas X_i da população em *ranks* de dominância, da seguinte maneira, no primeiro *rank* F_1 estão todas as partículas não dominadas por nenhuma outra partícula da população P , no segundo *rank* F_2 estão aquelas não dominadas por nenhuma outra partícula da população $P - F_1$, em F_3 estão aquelas não dominadas por nenhuma outra partícula da

população $P - F_1 - F_2$, e assim por diante. Após isso, é calculado, para cada partícula X_i , a sua distância de multidões, a qual, se baseia na média das distâncias entre as as duas partículas adjacentes em todas as dimensões do espaço objetivo. Então, os maiores *ranks* (F_1, F_2, \dots) são diretamente adicionados na memória até que todo o espaço de N partículas seja ocupado, caso somente parte de um dos *ranks* possa ser inserido na memória, ordenamos as partículas em ordem decrescente, de acordo com a distância de multidões, e tais partículas são adicionadas em ordem até que que a memória seja completamente ocupada.

Figura 4 – O processo de atualização do arquivo de memória do MESH usando o operado de distância de multidões



Fonte: Traduzido de (DEB et al., 2002a)

O MESH admite diferentes configurações para o seu funcionamento, são elas:

- E, a escolha do operador para o guia de enxame do PSO.
 - (E1) Selecionar a partícula mais próxima na memória.
 - (E2) Selecionar a partícula mais próxima na fronteira superior seguinte à fronteira da partícula atual.
- V, de qual grupo são as amostras que compõem o operador de mutação diferencial
 - (V1) População.
 - (V2) Memória.
 - (V3) População + Memória.
- D, qual das estratégias evolutivas para o operador de *Differential Evolution*, definidas em 2.3.1, será utilizada.

- (D1) DE/Rand/1/Bin.
- (D2) DE/Rand/2/Bin.
- (D3) DE/Best/1/Bin.
- (D4) DE/Current-to-best/1/Bin.
- (D5) DE/Current-to-rand/1/Bin.

Além das configurações tradicionais, neste trabalho uma configuração extra C foi adicionada, que diz respeito ao operador de distância de multidões do algoritmo MESH.

- (C1) Operador de distância de multidões, original do algoritmo NSGA-II
- (C2) Operador de distância de multidões SCD, definido na seção seguinte 2.3.3.1

Considerando todas as diferentes combinações de configurações possíveis, existem 60 diferentes maneiras de se implementar os operadores do algoritmo MESH, neste trabalho, nos limitamos a configuração E2V2D1, a qual será testada nas suas variações E2V2D1C1 e E2V2D1C2.

2.3.3.1 SCD - Distância de Multidões Especial

Além das configurações originais do algoritmo Multi-objective Evolutionary Swarm Hybridization (MESH), neste trabalho foi implementado uma configuração adicional que diz respeito ao operador de multidões.

Diferente do operador de distância de multidões original definido no algoritmo NSGA-II, a configuração adicional confere a possibilidade do uso da distância de multidões definida em (YUE et al., 2021).

Grande parte dos problemas de otimização tem a característica de serem multimodais, ou seja, apresentarem distintos máximos locais em diferentes pontos do espaço de decisão. Considerando tal contexto, é importante considerar a diversidade, não somente no espaço objetivo (como no operador original do NSGA-II), mas também no espaço de decisão. Para calcular a distância de multidões no espaço de decisão, temos a seguinte expressão:

$$CD_{i,x} = \sum_{j=1}^k (k - j + 1) d_{i,j} \quad (2.6)$$

onde $CD_{i,x}$ é a distância de multidões no espaço de decisão, i é o índice de uma partícula da população, j é o índice de uma partícula na vizinhança da partícula de índice i , $d_{i,j}$ é a distância euclidiana da i -ésima partícula na população inteira para a j -ésima partícula na vizinhança e k é o tamanho da vizinhança.

A distância de multidões no espaço objetivo da i -ésima partícula, denotada por $CD_{i,f}$, é calculada como no operador original do NSGA-II, com uma pequena modificação; a

distância de multidões não é calculada considerando somente um dos ranks de Pareto, mas sim toda a população.

Assim, é introduzido a distância de multidões especial da i -ésima partícula, denotado por SCD_i

$$SCD_i = \begin{cases} \max(CD_{i,x}, CD_{i,f}), & \text{se } CD_{i,x} > CD_{avg,x} \text{ ou } CD_{i,f} > CD_{avg,f} \\ \min(CD_{i,x}, CD_{i,f}), & \text{caso contrário} \end{cases} \quad (2.7)$$

onde $CD_{avg,x}$ e $CD_{avg,f}$ são as médias das distâncias de multidões no espaço de decisão e no espaço objetivo, respectivamente. No operador de distância de Multidões Especial, as partículas no último rank a entrarem na memória são escolhidas de acordo com a ordenação do SCD_i .

2.4 USINA HIDRELÉTRICA

A usina hidrelétrica, ou UHE, transforma a energia potencial da água, presente em um reservatório, em energia elétrica. A transformação acontece em duas etapas, a primeira delas é a transformação da energia potencial em energia cinética por meio de uma turbina. A turbina, por sua vez, está conectada a um gerador, o qual transforma a energia cinética em energia elétrica (OLIVEIRA, 2019).

2.4.1 Principais Componentes de uma UHE

Uma UHE é composta principalmente por 7 componentes, mencionados em (FERNANDES, 2015), são eles: reservatório, barragem, vertedouro, tomadas d'água, condutos forçados, turbina, gerador e o canal de fuga. É possível visualizar esses componentes graficamente na Figura 5.

O reservatório é onde uma grande quantidade de água é acumulada para que as necessidades de geração sejam atendidas. O reservatório opera em dois níveis: a cota mínima e a cota máxima de água. O volume de água inferior a cota mínima é chamado de volume morto e este não produz geração de energia. O volume útil do reservatório é a diferença entre os volumes de água na cota máxima e na cota mínima.

A barragem é uma barreira que tem como responsabilidade, reter grande quantidades de água armazenadas no reservatório. A tomada d'água é uma estrutura, localizada na barragem, responsável por controlar e receber o fluxo de água oriundo do reservatório. Além destas, existe o vertedouro que, assim como a tomada d'água, é localizado na barragem e tem como função o escoamento do excesso de água de forma segura.

Os condutos forçados levam a água do reservatório para a turbina, que por sua vez, converte a energia potencial da água no reservatório em alturas elevadas em energia cinética do movimento da hélice da turbina. O gerador, então, converte a energia cinética da turbina em energia elétrica que é direcionada as redes de transmissão para atender

Figura 5 – Principais componentes de uma UHE



Fonte: (FERNANDES, 2015)

aos consumidores. Ao final desse processo, a água é restituída ao rio original por meio do canal de fuga.

2.4.2 Balanço Hídrico De Um Reservatório De Uma UHE

O balanço hídrico diz respeito a variação de água em um reservatório em determinado intervalo de tempo. O controle do balanço hídrico é fundamental na operação de uma UHE, é por meio deste que é possível avaliar a variação de água no reservatório.

O volume do reservatório de água V_t , em determinado instante de tempo t , como mencionado em (OLIVEIRA, 2019) é determinado pela equação 2.8.

$$V_t = V_{t-1} + Q_{a_{t-1}} - Q_{t_{t-1}} - Q_{v_{t-1}} - E_{t-1} \cdot A_{t-1} \quad (2.8)$$

onde

- Q_a é a vazão afluyente, que é a vazão de água que chega ao reservatório;
- Q_t é a vazão turbinada, que é a vazão de água direcionada do reservatório para a turbina;
- Q_v é a vazão vertida, que é a vazão do excesso de água escoada pelos vertedouros;
- E é a taxa de evaporação;
- A é a área da superfície da água no reservatório.

Uma das variáveis cruciais que tem influência direta na geração de energia de uma UHE é a altura da queda bruta hb , que é determinada pela subtração da cota montante fc_m (altura do volume de água no reservatório) pela cota jusante fc_j (altura do volume de água que sai do reservatório). Em geral os valores para as cotas jusante e montante são estimados por um polinômio de quarto grau, como descritas em (OLIVEIRA, 2019).

$$fc_m_t = a_0 + a_1 \cdot V_t + a_2 \cdot V_t^2 + a_3 \cdot V_t^3 + a_4 \cdot V_t^4 \quad (2.9)$$

$$fc_j_t = b_0 + b_1 \cdot (Qt_t + Qv_t) + b_2 \cdot (Qt_t + Qv_t)^2 + b_3 \cdot (Qt_t + Qv_t)^3 + b_4 \cdot (Qt_t + Qv_t)^4 \quad (2.10)$$

Nas equação 2.9 vê-se que a altura da cota jusante é uma função do volume V_t de água no reservatório, enquanto a equação 2.10 mostra que a altura da cota jusante é uma função da soma da vazões para fora do reservatório.

Os coeficientes a_0, a_1, \dots, a_4 e b_0, b_1, \dots, b_4 são estimados por meio da regressão de um polinômio de quarto grau com o uso de dados históricos da UHE.

Dessa forma, a queda bruta hb é definida como

$$hb_t = fc_m_t - fc_j_t$$

de acordo com (OLIVEIRA, 2019).

2.4.3 Modelo Matemático da Operação de UHEs em cascata

O modelo matemático do funcionamento da UHE em cascata, proposto em (OLIVEIRA, 2019), é uma formulação para o despacho elétrico com 2 funções objetivo. Neste trabalho, uma terceira função objetivo foi adicionada, definida em (MARCELINO et al., 2021).

O modelagem matemática do problema é dinâmica, ou seja, as variáveis do sistema mudam de acordo com o tempo. A natureza dinâmica do problema surge da necessidade de considerar o balanço hídrico do volume de cada uma das UHEs em cascata, uma vez que existe interferência no nível do reservatório de uma UHE em razão das vazões defluentes de outra UHE.

Para determinada UHE u em cascata, o volume do seu reservatório no tempo t pode ser determinado pela equação 2.11(OLIVEIRA, 2019).

$$V_{u,t} = V_{u,t-1} + c(Qa_{u,t-1} + Qt_{w,td} + Qv_{w,td} - Qt_{u,t-1} - Qv_{u,t-1}) - E_{u,t-1} \cdot A_{u,t-1} \quad (2.11)$$

onde c , é uma constante usada para converte vazão de água em volume na unidade de tempo t .

É importante perceber que agora temos um índice extra em cada uma das variáveis, que identificam a UHE , na equação 2.11 temos duas usinas u e w , tal que $u \neq w$. Além disso, td indica o intervalo de tempo para o deslocamento de água entre as usinas w e u , $Q_{w,td}$ e $Q_{v,w,td}$ são as vazões turbinada e vertida da usina w no intervalo td , respectivamente.

As funções objetivo maximizam a eficiência da usina sob diferentes perspectivas, e o espaço de decisão é a vazão em m^3/s de cada uma das unidades geradoras. A potência $ph_{uj,t}$ em MW , na usina u gerada pela unidade geradora j no instante t , segundo o modelo descrito em (MARCELINO et al., 2021), é definida pela equação 2.12.

$$ph_{uj,t} = g \cdot k \cdot [\rho_0 + \rho_1 hl_{uj,t} + \rho_2 q_{uj,t} + \rho_3 hl_{uj,t} q_{uj,t} + \rho_4 hl_{uj,t}^2 + \rho_5 q_{uj,t}^2] \cdot [hb_{uj,t} - \Delta_{H_{uj,t}}] \cdot q_{uj,t} \quad (2.12)$$

onde

- g é a aceleração da gravidade ($9.8m/s^2$);
- k é uma constante para a conversão de HP em MW ;
- $\rho_0, \rho_1, \dots, \rho_5$ são coeficientes obtidos por meio de métodos de regressão com dados históricos;
- $hb_{uj,t}$ é a altura da queda bruta da usina u na unidade geradora j no tempo t em metros;
- $hl_{uj,t}$ é a altura da queda líquida da usina u na unidade geradora j no tempo t em metros;
- $q_{uj,t}$ é a vazão turbinada da usina u na unidade geradora j no tempo t em m^3/s ;
- $\Delta_{H_{uj,t}}$ são as perdas totais referentes ao atrito nos condutos forçados da usina u na unidade geradora j no tempo t em metros.

Tabela 1 – Coeficientes Operativos

Coeficiente	Valor
ρ_0	1,4630e-01
ρ_1	1,8076e-02
ρ_2	5,0502e-03
ρ_3	-3,5254e-03
ρ_4	-1,1234e-03
ρ_5	1,4507e-05

Fonte: (MARCELINO, 2017)

Como mencionado anteriormente, o espaço de decisão é o espaço definido pelos vetores da forma $\mathbf{q}_t = [q_{11,t}, q_{12,t}, \dots, q_{UJ_u,t}]$, tais vetores são as possíveis entradas para as funções objetivo.

A primeira função objetivo F_1 , proposta em (OLIVEIRA, 2019), do modelo proposto faz referência à eficiência energética do modelo e visa maximizar a potência gerada ph_{jt} por vazão de água

$$\text{Maximizar } F_1(\mathbf{q}_t) = \frac{1}{U} \sum_{u=1}^U \left(\frac{\sum_{j=1}^{J_u} ph_{uj,t}}{\sum_{j=1}^{J_u} q_{uj,t}} \right)$$

onde U é a quantidade de usinas em cascata e J_u é quantidade de unidades geradoras na usina u .

A segunda função objetivo F_2 , proposta em (OLIVEIRA, 2019), visa a maximização dos níveis de água no reservatório. Manter altos níveis de volume de água no reservatório aumenta a robustez da UHE a períodos de seca, além disso, ao elevar o volume de água no reservatório, o valor da cota montante também é elevado, assim elevando a potência energética produzida

$$\text{Maximizar } F_2(\mathbf{q}_t) = \frac{1}{U} \sum_{u=1}^U \left(\frac{V_{u,t}}{V_u^{max}} \right)$$

onde V_u^{max} é o volume máximo do reservatório

A terceira função objetivo F_3 , foi adaptada para o caso das UHE's em cascata de (MARCELINO et al., 2015), minimiza a distância euclidiana entre as vazões das unidade geradoras otimizadas e as vazões tradicionais no modelo de controle conjunto, onde todas as unidades geradoras possuem a mesma vazão (maneira como a UHE costuma operar). Essa função tem como objetivo aumentar a confiança da equipe de operadores da UHE nas vazões otimizadas, buscando por aquelas mais próximas das vazões no controle conjunto que ainda maximizem a eficiência energética e o volume de água nos reservatórios.

$$\text{Minimizar } F_3(\mathbf{q}_t) = \frac{1}{U} \sum_{u=1}^U \left(\sum_{j=1}^{J_u} (q_{uj,t} - q_{u,cc})^2 \right)$$

onde $q_{u,cc}$ é a vazão das unidades geradoras da usina u no modelo de controle conjunto.

Além das funções objetivo, o espaço de decisão está restrito à determinadas restrições (OLIVEIRA, 2019). A primeira delas, descrita na equação 2.13, determina que a energia gerada pela UHE precisa ser igual à demanda $Dm_{u,t}$ com determinada tolerância de erro ϵ (aproximadamente 0.5%).

$$Dm_{u,t} \cdot (1 - \epsilon) \leq \sum_{j=1}^{J_u} ph_{uj,t} \leq Dm_{u,t} \cdot (1 + \epsilon) \quad (2.13)$$

Além disso, a vazão de água em determinada unidade geradora precisa respeitar os limites de vazão mínima q_{uj}^{min} e de vazão máxima q_{uj}^{max} da usina u . O mesmo deve ser verdade para o volume de água no reservatório que deve atender os limites de volume mínimo V_u^{min} e volume máximo V_u^{max} .

$$q_{uj}^{min} \leq q_{uj,t} \leq q_{uj}^{max}$$

$$V_u^{min} \leq V_{u,t} \leq V_u^{max}$$

A vazão defluente das UHE's também precisa respeitar um intervalo $[Qd_u^{min}, Qd_u^{max}]$, esses limites existem para a prevenção de alagamentos nas regiões próximas às UHE's.

$$Qd_u^{min} \leq Qv_{u,t} + \sum_{j=1}^{J_u} q_{uj,t} \leq Qd_u^{max}$$

Um limite máximo Qv_u^{max} , também é imposto para a vazão vertida.

$$Qv_{u,t} \leq Qv_u^{max}$$

Por último, a potência gerada pela unidade geradora j deve estar dentro dos limites de mínimo ph_{uj}^{min} e de máximo ph_{uj}^{max} para tal unidade geradora da usina u .

$$ph_{uj}^{min} \cdot Z_{uj,t} \leq ph_{uj,t} \leq ph_{uj}^{max} \cdot Z_{uj,t}$$

Onde $Z_{uj,t} \in \{0, 1\}$ é uma variável binária, que indica se unidade geradora j da usina u está ativa ($Z_{uj,t} = 1$) ou inativa ($Z_{uj,t} = 0$) no instante t .

Dessa forma, o modelo matemático descrito é definido pela equação 2.14

$$\begin{aligned} \max \quad F_1(\mathbf{q}_t) &= \frac{1}{U} \sum_{u=1}^U \left(\frac{\sum_{j=1}^{J_u} ph_{uj,t}}{\sum_{j=1}^{J_u} q_{uj,t}} \right) \\ \max \quad F_2(\mathbf{q}_t) &= \frac{1}{U} \sum_{u=1}^U \left(\frac{V_{u,t}}{V_u^{max}} \right) \\ \min \quad F_3(\mathbf{q}_t) &= (-1) \cdot \frac{1}{U} \sum_{u=1}^U \left(\sum_{j=1}^{J_u} (q_{uj,t} - q_{u,cc})^2 \right) \end{aligned}$$

sujeito a

$$Dm_{u,t} \cdot (1 - \epsilon) \leq \sum_{j=1}^{J_u} ph_{uj,t} \leq Dm_{u,t} \cdot (1 + \epsilon) \quad (2.14)$$

$$q_{uj}^{min} \leq q_{uj,t} \leq q_{uj}^{max}$$

$$V_u^{min} \leq V_{u,t} \leq V_u^{max}$$

$$Qd_u^{min} \leq Qv_{u,t} + \sum_{j=1}^{J_u} q_{uj,t} \leq Qd_u^{max}$$

$$Qv_{u,t} \leq Qv_u^{max}$$

$$ph_{uj}^{min} \cdot Z_{uj,t} \leq ph_{uj,t} \leq ph_{uj}^{max} \cdot Z_{uj,t}$$

$$Z_{uj,t} \in \{0, 1\}$$


3 METODOLOGIA

Neste capítulo são abordadas a técnica de medida de desempenho (métrica de hipervolume) e a técnica de inferência (Kruskal-Wallis) para comparação do algoritmo MESH e demais métodos multiobjetivo. Como primeiro passo, funções de teste foram utilizadas para medir o desempenho dos algoritmos. Tais funções estão descritas na Seção 3.4.

3.1 MEDIDA DE HIPERVOLUME (HV)

Como visto em (AUDET et al., 2021), a métrica de hipervolume, também chamada de *S-metric*, é o hiper-volume de um espaço da Fronteira de Pareto S , encontrada pelo algoritmo, até um determinado ponto de referência $r \in \mathbb{R}^m$. É importante mencionar que, para qualquer ponto $z \in S$, é necessário que $z \prec r$.

Figura 6 – Ilustração da medida de hipervolume para um problema biobjetivo



Adaptado de (AUDET et al., 2021)

O hipervolume é a medida mais comumente usada na avaliação do desempenho de algoritmos multiobjetivos pelo fato de que é estritamente monotônico, ou seja, sejam A, B aproximações para a fronteira de Pareto encontrados por 2 algoritmos distintos, se todas os pontos em B são dominados por algum ponto em A (escrevemos $A \prec B$), então $HV(A, r) > HV(B, r)$.

Em outras palavras:

$$A \prec B \Rightarrow HV(A, r) > HV(B, r)$$

3.2 TESTE ESTATÍSTICOS - TESTE U DE MANN-WHITNEY

Dada a natureza estocástica de algoritmos evolutivos, podemos ter diferentes resultados para a métrica de hipervolume, mencionada anteriormente, para diferentes execuções do algoritmo.

Dessa forma, se faz necessário avaliar a distribuição dos resultados de cada um dos algoritmos para uma comparação precisa entre tais. Serão usados testes de hipótese que avaliam se a distribuição de resultados de dois algoritmos distintos são significativamente diferentes.

Neste trabalho, o testes de hipótese para a comparação de desempenho dos algoritmos é o Teste U de Mann-Whitney, definido em (MANN; WHITNEY, 1947), que tem as seguintes hipóteses nula e alternativa H_0 e H_1 , respectivamente.

$$\begin{cases} H_0 = \forall u F(u) = G(u) \\ H_1 = \forall u F(u) < G(u) \end{cases}$$

onde F e G são as funções de distribuição acumulada de onde vieram as amostras de duas populações i e j . A hipótese nula é de que as amostras de ambas as populações vem da mesma distribuição, enquanto a hipótese alternativa indica que a primeira população é estocasticamente menor do que a segunda. No caso deste trabalho, as populações dizem respeito aos resultados da medida de hipervolume de dois algoritmos distintos.

A opção pelo Teste U de Mann-Whitney em opção à análise de variância tradicional (ANOVA), se dá pelo motivo de que o método ANOVA é paramétrico e possui diferentes pressupostos sobre a distribuição das populações, que não podem ser garantidos para as populações de hipervolumes estudadas, enquanto o Teste U de Mann-Whitney é não paramétrico e tem como único pressuposto que as amostras são mutuamente independentes.

3.3 PARETO COMBINADO

O conjunto de soluções Pareto combinado é dado pelas melhores soluções em diferentes execuções do mesmo algoritmo. As fronteiras de Pareto encontradas em cada execução do algoritmo são combinadas e são eliminados os pontos dominados, de maneira que sobrem somente as melhores soluções dentre todas as execuções.

3.4 PROBLEMAS DE *BENCHMARK*

Um dos objetivos da execução deste trabalho é avaliar o desempenho do algoritmo Multi-objective Evolutionary Swarm Hybridization (MESH) em problemas de otimização com 3 funções objetivo, e por isso, todos os problemas de *benchmark* que serão apresentado nessa seção estão na sua versão com 3 objetivos.

A implementação das funções de *benchmark* utilizadas estão disponíveis na biblioteca para a linguagem Python; *pymoo*, disponível em (Blank; Deb, 2020).

3.4.1 DTLZ

Propostas inicialmente em (DEB et al., 2002b), as DTLZ's são uma classe de problemas multiobjetivo sintéticos para a avaliação do desempenho de algoritmos de otimização. Tais problemas são definidos na sua forma geral, com qualquer dimensão do espaço objetivo, no entanto, como mencionado anteriormente, neste trabalho nos restringimos a um espaço objetivo de tamanho 3.

3.4.1.1 DTLZ 1

Definição:

$$\begin{aligned} \min \quad f_1(\mathbf{x}) &= \frac{1}{2}x_1 \cdot x_2 \cdot (1 + g(\mathbf{x}_3)) \\ f_2(\mathbf{x}) &= \frac{1}{2}x_1 \cdot (1 - x_2) \cdot (1 + g(\mathbf{x}_3)) \\ f_3(\mathbf{x}) &= \frac{1}{2}(1 - x_1) \cdot (1 + g(\mathbf{x}_3)) \end{aligned}$$

sujeito a $\forall i (0 \leq x_i \leq 1)$

Onde \mathbf{x}_3 é um vetor com todas as variáveis exceto x_1 e x_2 e $g(\mathbf{x}_3)$ é:

$$g(\mathbf{x}_3) = 100 \cdot [|\mathbf{x}_3| + \sum_{x_i \in \mathbf{x}_3} (x_i - 0.5)^2 - \cos(20\pi(x_i - 0.5))]$$

Fronteira Ótima: A fronteira de Pareto ótima corresponde a $x_i = 0.5, \forall x_i \in \mathbf{x}_3$ e os valores do espaço objetivo estão no plano $f_1(\mathbf{x}) + f_2(\mathbf{x}) + f_3(\mathbf{x}) = 0.5$.

Figura 7 – Gráfico da fronteira de Pareto do problema teste DTLZ 1




Gráfico construído com assistência da biblioteca Plotly

3.4.1.2 DTLZ 2

Definição:

$$\begin{aligned} \min \quad & f_1(\mathbf{x}) = \cos(\pi/2 \cdot x_1) \cdot \cos(\pi/2 \cdot x_2) \cdot (1 + g(\mathbf{x}_3)) \\ & f_2(\mathbf{x}) = \cos(\pi/2 \cdot x_1) \cdot \sin(\pi/2 \cdot x_2) \cdot (1 + g(\mathbf{x}_3)) \\ & f_3(\mathbf{x}) = \sin(\pi/2 \cdot x_1) \cdot (1 + g(\mathbf{x}_3)) \\ \text{sujeito a} \quad & \forall i (0 \leq x_i \leq 1) \end{aligned}$$

Onde \mathbf{x}_3 é um vetor com todas as variáveis exceto x_1 e x_2 e $g(\mathbf{x}_3)$ é:

$$g(\mathbf{x}_3) = \sum_{x_i \in \mathbf{x}_3} (x_i - 0.5)^2$$

Fronteira Ótima: A fronteira de Pareto ótima corresponde a $x_i = 0.5, \forall x_i \in \mathbf{x}_3$.

Figura 8 – Gráfico da fronteira de Pareto do problema teste DTLZ 2

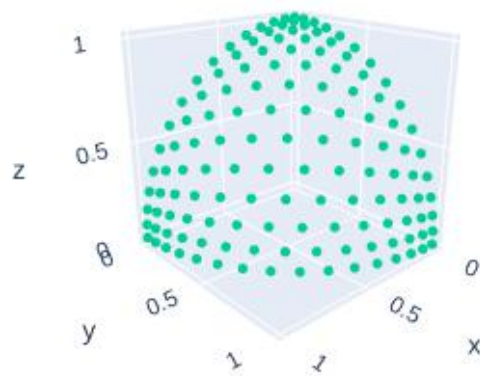


Gráfico construído com assistência da biblioteca Plotly

3.4.1.3 DTLZ 3

Definição:

$$\begin{aligned} \min \quad & f_1(\mathbf{x}) = \cos(\pi/2 \cdot x_1) \cdot \cos(\pi/2 \cdot x_2) \cdot (1 + g(\mathbf{x}_3)) \\ & f_2(\mathbf{x}) = \cos(\pi/2 \cdot x_1) \cdot \sin(\pi/2 \cdot x_2) \cdot (1 + g(\mathbf{x}_3)) \\ & f_3(\mathbf{x}) = \sin(\pi/2 \cdot x_1) \cdot (1 + g(\mathbf{x}_3)) \\ \text{sujeito a} \quad & \forall i (0 \leq x_i \leq 1) \end{aligned}$$

Onde \mathbf{x}_3 é um vetor com todas as variáveis exceto x_1 e x_2 e $g(\mathbf{x}_3)$ é:

$$g(\mathbf{x}_3) = 100 \cdot [|\mathbf{x}_3| + \sum_{x_i \in \mathbf{x}_3} (x_i - 0.5)^2 - \cos(20\pi(x_i - 0.5))]$$

Fronteira Ótima: A fronteira de Pareto ótima corresponde a $x_i = 0.5, \forall x_i \in \mathbf{x}_3$.

Figura 9 – Gráfico da fronteira de Pareto do problema teste DTLZ 3

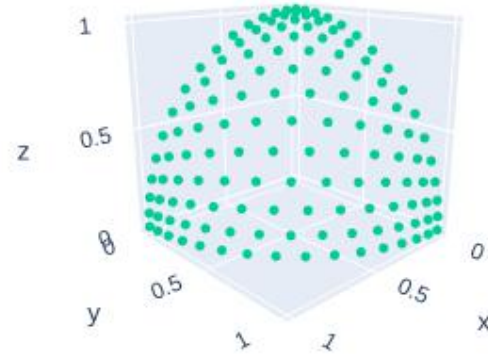


Gráfico construído com assistência da biblioteca Plotly

3.4.1.4 DTLZ 5

Definição:

$$\begin{aligned}
 \min \quad & f_1(\mathbf{x}) = \cos(\pi/2 \cdot \theta_1) \cdot \cos(\pi/2 \cdot \theta_2) \cdot (1 + g(\mathbf{x}_3)) \\
 & f_2(\mathbf{x}) = \cos(\pi/2 \cdot \theta_1) \cdot \sin(\pi/2 \cdot \theta_2) \cdot (1 + g(\mathbf{x}_3)) \\
 & f_3(\mathbf{x}) = \sin(\pi/2 \cdot \theta_1) \cdot (1 + g(\mathbf{x}_3)) \\
 \text{sujeito a} \quad & \forall i (0 \leq x_i \leq 1)
 \end{aligned}$$

Onde \mathbf{x}_3 é um vetor com todas as variáveis exceto x_1 e x_2 e θ_i e $g(\mathbf{x}_3)$ é:

$$\theta_i = \frac{\pi}{4(1 + g(\mathbf{x}_3))} (1 + 2 \cdot g(\mathbf{x}_3) \cdot x_i)$$

$$g(\mathbf{x}_3) = \sum_{x_i \in \mathbf{x}_3} (x_i - 0.5)^2$$

Fronteira Ótima: A fronteira de Pareto ótima corresponde a $x_i = 0.5, \forall x_i \in \mathbf{x}_3$ e os valores do espaço objetivo estão no plano $f_1(\mathbf{x})^2 + f_2(\mathbf{x})^2 + f_3(\mathbf{x})^2 = 1$.

Figura 10 – Gráfico da fronteira de Pareto do problema teste DTLZ 5




Gráfico construído com assistência da biblioteca Plotly

3.4.1.5 DTLZ 6

Definição:

$$\begin{aligned} \min \quad & f_1(\mathbf{x}) = \cos(\pi/2 \cdot \theta_1) \cdot \cos(\pi/2 \cdot \theta_2) \cdot (1 + g(\mathbf{x}_3)) \\ & f_2(\mathbf{x}) = \cos(\pi/2 \cdot \theta_1) \cdot \sin(\pi/2 \cdot \theta_2) \cdot (1 + g(\mathbf{x}_3)) \\ & f_3(\mathbf{x}) = \sin(\pi/2 \cdot \theta_1) \cdot (1 + g(\mathbf{x}_3)) \\ \text{sujeito a} \quad & \forall i (0 \leq x_i \leq 1) \end{aligned}$$

Onde \mathbf{x}_3 é um vetor com todas as variáveis exceto x_1 e x_2 e θ_i e $g(\mathbf{x}_3)$ é:

$$\theta_i = \frac{\pi}{4(1 + g(\mathbf{x}_3))} (1 + 2 \cdot g(\mathbf{x}_3) \cdot x_i)$$

$$g(\mathbf{x}_3) = \sum_{x_i \in \mathbf{x}_3} x_i^{0.1}$$

Fronteira Ótima: A fronteira de Pareto ótima corresponde a $x_i = 0, \forall x_i \in \mathbf{x}_3$.

Figura 11 – Gráfico da fronteira de Pareto do problema teste DTLZ 6




Gráfico construído com assistência da biblioteca Plotly

3.4.1.6 DTLZ 7

Definição:

$$\begin{aligned}
 \min \quad & f_1(\mathbf{x}) = x_1 \\
 & f_2(\mathbf{x}) = x_2 \\
 & f_3(\mathbf{x}) = (1 + g(\mathbf{x}_3)) \cdot h(f_1(\mathbf{x}), f_2(\mathbf{x}), g(\mathbf{x}_3)) \\
 \text{sujeito a} \quad & \forall i (0 \leq x_i \leq 1)
 \end{aligned}$$

Onde \mathbf{x}_3 é um vetor com todas as variáveis exceto x_1 e x_2 e $h(f_1(\mathbf{x}), f_2(\mathbf{x}), g(\mathbf{x}_3))$ e $g(\mathbf{x}_3)$ é:

$$\begin{aligned}
 h(f_1(\mathbf{x}), f_2(\mathbf{x}), g(\mathbf{x}_3)) &= 3 - \sum_{i=1}^2 \frac{f_i(\mathbf{x})}{1 + g(\mathbf{x}_3)} (1 + \sin(3\pi \cdot f_i(\mathbf{x}))) \\
 g(\mathbf{x}_3) &= 1 + \frac{9}{|\mathbf{x}_3|} \sum_{x_i \in \mathbf{x}_3} x_i
 \end{aligned}$$

Fronteira Ótima: A fronteira de Pareto ótima corresponde a $x_i = 0, \forall x_i \in \mathbf{x}_3$.

Figura 12 – Gráfico da fronteira de Pareto do problema teste DTLZ 7




Gráfico construído com assistência da biblioteca Plotly

4 RESULTADOS

Os experimentos realizados neste trabalho comparam o desempenho do algoritmo Multi-objective Evolutionary Swarm Hybridization (MESH) frente três outras meta-heurísticas bem estabelecidas, são elas os algoritmos NSGA-II (DEB et al., 2002a), NSGA-III (DEB; JAIN, 2014) (JAIN; DEB, 2014) e MOEA/D (ZHANG; LI, 2007). Todos os algoritmos foram implementados na linguagem de programação Python em sua versão 3.7.12, pela biblioteca *pymoo* (Blank; Deb, 2020). Todas as execuções dos 4 algoritmos tiveram como critério de parada o número de avaliações das funções objetivo de 15000 e o tamanho da população de 100 partículas.

4.1 DTLZ

Neste experimento, os 4 algoritmos foram executados 30 vezes para cada uma das DTLZ's mencionadas em 3.4.1, cada uma dessas execuções nos confere um valor de hipervolume, com ponto de referência $r = [11, 11, 11]$. As amostras de hipervolume são comparadas entre os algoritmos pelo teste U de Mann-Whitney, como mencionado na Seção 3.2.

4.1.1 Soluções Pareto Combinadas

A Figura 13 apresenta o resultado das soluções pareto combinadas de duas diferentes configurações do algoritmo MESH (E2V2D1C1 e E2V2D1C2), assim como, as soluções encontradas pelos outros três algoritmos citados anteriormente (MOEA/D, NSGA-II e NSGA-III) e os hipervolumes de cada uma das fronteiras em vermelho.

É possível perceber que a configuração do algoritmo MESH, E2V2D1C1 foi a que encontrou as fronteira pareto combinadas com maior valor de hipervolume, com exceção das DTLZ's 6 e 7, nas quais os maiores hipervolumes foram encontrados são provenientes da configuração E2V2D1C1 do algoritmo MESH e do NSGA-III. Além disso, é possível perceber um desempenho bem inferior da configuração E2V2D1C2 do algoritmo MESH nos problemas DTLZ1 e DTLZ3, onde a fronteira de Pareto encontrada é dominada pelo ponto de referência.

De forma geral, as fronteiras Pareto Combinadas sugerem que a configuração E2V2D1C1 do algoritmo MESH possui um desempenho superior aos outros 4 algoritmos, no entanto, ainda se faz necessário a realização de um análise estatística sob as soluções de cada uma das 30 execuções.

Figura 13 – Gráfico da fronteiras Pareto Combinadas do problema teste DTLZ

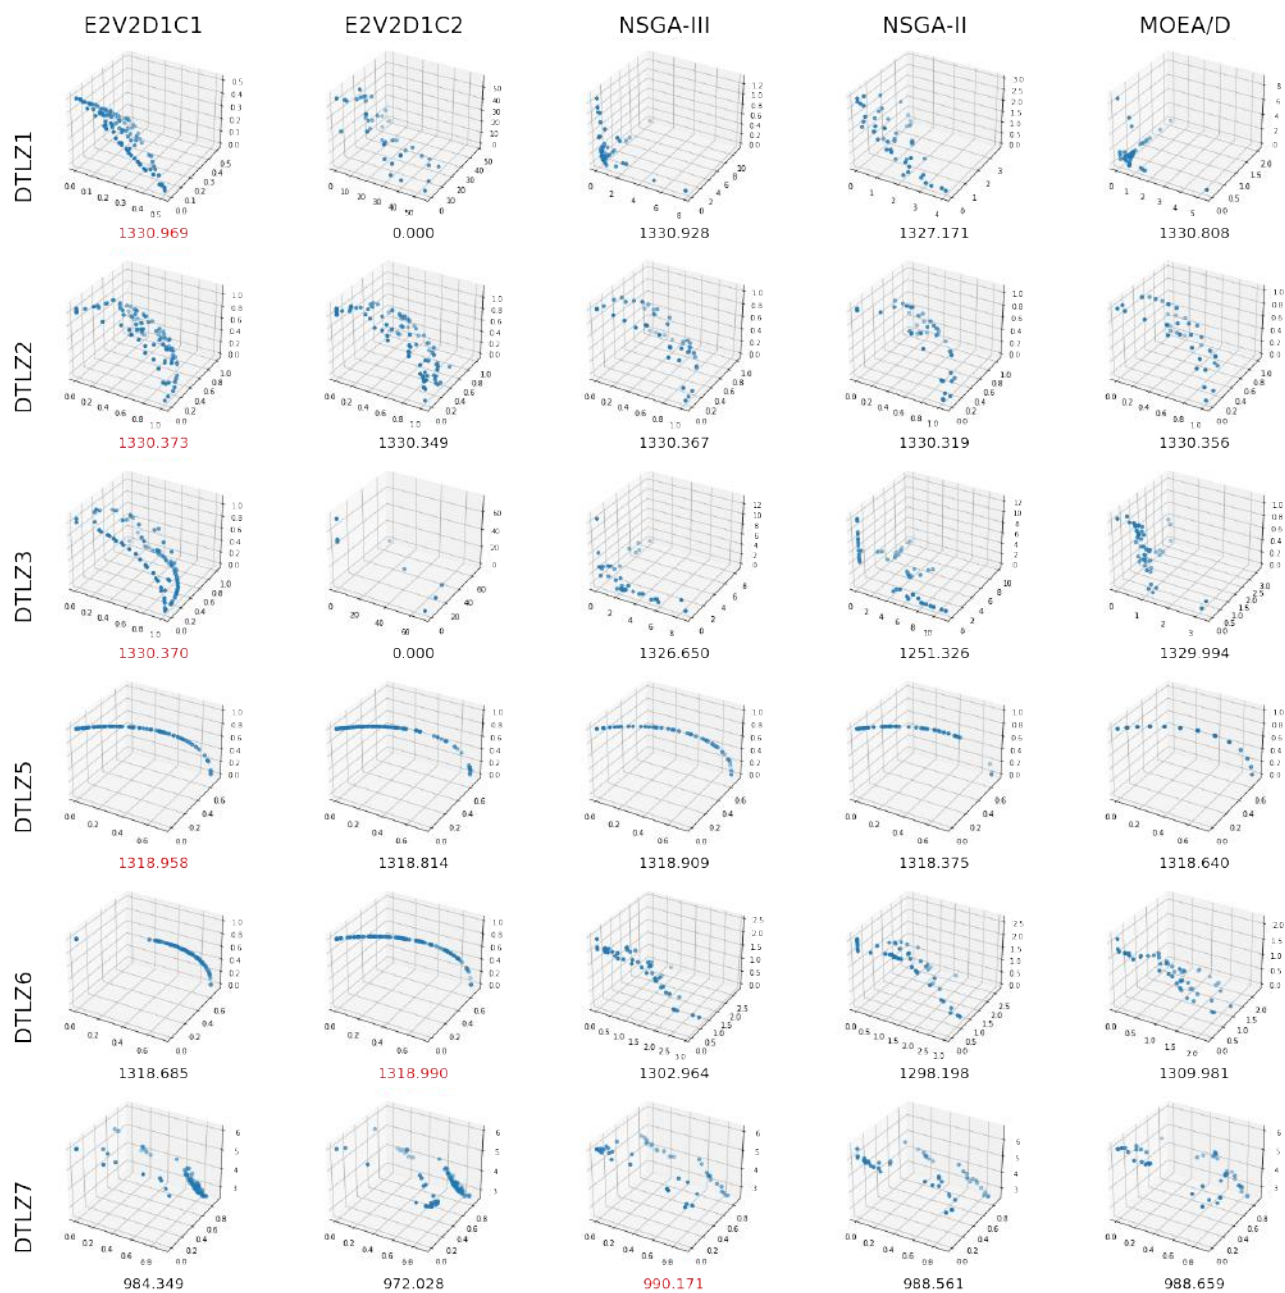


Gráfico construído com assistência da biblioteca Matplotlib

Valores em vermelho indicam os maiores resultados para a Fronteira de Pareto

4.1.2 Análise Estatística dos Resultados

Nos quadros 1 e 2 é possível ver os resultados para as médias e desvios padrão dos hipervolumes encontrados em 30 execuções de cada um dos algoritmos.

Diferentemente dos resultados Pareto Combinados, na DTLZ 2, o NSGA-III apresentou a melhor das médias dentre todos os algoritmos, enquanto na DTLZ5 o maior dos resultados foi atribuído ao algoritmo NSGA-II, assim como na DTLZ7.

Avaliando os problemas de maneira generalizada, pelo quadro 2, o algoritmo que parece apresentar menor variância de resultados por execução é a configuração E2V2D1C1 do MESH.

Uma análise isolada das médias em cada DTLZ não é o suficiente, assim, sendo necessária a aplicação de um teste estatístico para garantia de que as distribuições dos hipervolumes de cada um dos algoritmos são estatisticamente diferentes.

Quadro 1 – Média dos resultados para o hipervolumes de cada um dos algoritmos

	E2V2D1C1	E2V2D1C2	NSGA-III	NSGA-II	MOEA/D
DTLZ1	1330.312 (+)	-	1326.977 (-)	1170.154 (-)	1290.284 (-)
DTLZ2	1330.349 (-)	1330.310 (-)	1330.409 (+)	1330.128 (-)	1330.399 (-)
DTLZ3	1256.378 (+)	-	1018.781 (-)	530.785 (-)	1195.077 (-)
DTLZ5	1319.007 (-)	1318.972 (-)	1318.481 (-)	1319.025 (+)	1318.476 (-)
DTLZ6	1318.964 (-)	1319.036 (+)	1298.700 (-)	1294.762 (-)	1297.758 (-)
DTLZ7	896.804 (-)	762.861 (-)	985.405 (-)	990.547 (=)	944.577 (=)

(+) Indica que aqueles são os maiores resultados encontrados para a média dos hipervolumes.

(-) Indica que existe diferença estatística entre a distribuição daquele hipervolume e a distribuição do maior hipervolume do problema.

(=) Indica que não existe diferença estatística entre a distribuição daquele hipervolume e a distribuição do maior hipervolume do problema.

Quadro 2 – Desvios Padrão dos resultados para o hipervolumes de cada um dos algoritmos

	E2V2D1C1	E2V2D1C2	NSGA-III	NSGA-II	MOEA/D
DTLZ1	1.662	-	4.452	199.272	59.465
DTLZ2	0.006	0.008	0.001	0.238	0.006
DTLZ3	231.203	-	323.325	460.942	294.856
DTLZ5	0.007	0.009	0.053	0.006	0.219
DTLZ6	0.011	0.010	2.975	2.468	6.560
DTLZ7	68.984	87.286	26.182	0.569	106.322

Para verificar que os resultados das melhores médias encontradas para cada DTLZ são estatisticamente diferentes das médias encontradas pelos outros algoritmos temos os P-valores no Teste U de Mann-Whitney (seção 3.2).

O Quadro 3 apresenta os P-valores da comparação da distribuição do melhor algoritmo para a DTLZ especificada, frente os outros 4 algoritmos. A um nível de significância $\alpha = 0.05$, a hipótese nula no teste U de Mann-Whitney é negada, de que as distribuições são similares.

4.1.3 Observações Finais

O algoritmo MESH apresenta um desempenho competitivo nas DTLZ's com 3 objetivos frente os algoritmos tradicionais, visto que, quando considerado o hipervolume das

Quadro 3 – p-valores para o Teste U de Mann-Whitney

	E2V2D1C1	E2V2D1C2	NSGA-III	NSGA-II	MOEA/D
DTLZ1 (E2V2D1C1)	-	-	1.505e-07	1.844e-11	1.737e-10
DTLZ2 (NSGA-III)	1.509e-11	1.509e-11	-	1.509e-11	5.468e-11
DTLZ3 (E2V2D1C1)	-	-	7.366e-08	5.117e-10	2.229e-04
DTLZ5 (NSGA-II)	4.445e-10	1.509e-11	1.509e-11	-	1.509e-11
DTLZ6 (E2V2D1C2)	1.509e-11	-	1.509e-11	1.509e-11	1.509e-11
DTLZ7 (NSGA-II)	1.844e-11	1.509e-11	0.018	-	0.999

Valores muito próximos de 0 são truncados para 1.509e-11

fronteiras Pareto Combinadas, a sua configuração E2V2D1C1 teve desempenho superior em 5 de 7 DTLZ's (graficamente), enquanto, quando considerada a média das execuções as suas configurações E2V2D1C1 e E2V2D1C2 tiveram desempenho superior em 2 DTLZ's e em 1 DTLZ em relação à média, respectivamente.

Apesar de ter tido os melhores resultados de hipervolume na DTLZ6, a configuração E2V2D1C2 não obteve bons resultados, no geral, nas DTLZ's. Ao considerar que a fronteira encontrada nos problemas DTLZ1 e DTLZ3 é dominada pelo ponto de referência e que o seu resultado na DTLZ7 foi, notadamente, menor que dos outros algoritmos surge a hipótese de que o operador de distância de multidões, descrito em 2.3.3.1, não aprimorou o algoritmo no contexto das DTLZ's.

4.2 MODELO DA USINA HIDRELÉTRICA EM CASCATA

Como o modelo proposto para a usina hidrelétrica em cascata tem caráter dinâmico, uma estratégia de reavaliação da Fronteira de Pareto do modelo foi empregada a cada vez que a fronteira é alterada com o tempo. A granularidade de tempo empregada neste trabalho é horária, de maneira que, as variáveis dinâmicas do modelo variam de hora em hora e temos um problema de otimização para cada uma das 24 horas em um dia. Tal estratégia para a otimização do modelo dinâmico foi implementada inicialmente em (OLIVEIRA, 2019).

Figura 14 – Diagrama para o processo de otimização da Usina Hidrelétrica



Fonte: (OLIVEIRA, 2019)

As variáveis dinâmicas do modelo (Volume dos reservatórios, Vazões defluentes) são transmitidas de uma iteração do modelo para a próxima, enquanto as variáveis estáticas são definidas para cada hora t e independem da iteração anterior $t - 1$. As variáveis dinâmicas e estáticas juntas definem o modelo que será otimizado na hora t .

Para cada uma das horas, é realizado 30 execuções do algoritmo que combinam as soluções encontradas em uma fronteira Pareto combinada. A partir de tal conjunto de soluções, uma única solução deve ser selecionada, os valores das variáveis no espaço de decisão de tal solução (vazões turbinadas), vão definir os valores futuros das variáveis dinâmicas. Neste trabalho, a solução selecionada é aquela mais próxima do ponto com a média de todas as soluções.

4.2.1 Descrição do sistemas de UHE's em cascata

O sistema de usinas contém duas UHE's em cascata, a primeira delas $U1$ possui 8 unidades geradoras e capacidade máxima de $528MW$, enquanto, a segunda $U2$, que recebe a vazão da $U1$, com 6 unidades geradoras e capacidade de $396MW$.

Os reservatórios de ambas as UHE possuem um volume máximo de $19528hm^3$ e um volume mínimo de $4250hm^3$ e são inicializados, no hora $t = 0$, com 80% da sua capacidade máxima.

Nas tabela 2 são apresentados os coeficientes dos polinômios para o cálculo da cota montante fc_m_t e da cota jusante fc_j_t , ambas as cotas são calculadas com os mesmos coeficientes nas duas UHE's.

A UHE $U1$ não recebe vazão de nenhuma outra UHE, dessa forma, os termos $Qt_{w,td}$ e Qvw,td são nulos no cálculo do volume do reservatório. No caso da UHE $U2$, o mesmo não é verdade, já que ela recebe as vazões da UHE $U1$, assim, consideramos o tempo td do deslocamento de água entre $U1$ e $U2$ é de 2 horas.

Tabela 2 – Coeficientes dos polinômios da cota montante e da cota jusante

Cota Montante				
a_0	a_1	a_2	a_3	a_4
5.30e02	6.08e-03	-4.84e-07	2.20e-11	-3.85e-16
Cota Jusante				
b_0	b_1	b_2	b_3	b_4
5.15e02	1.61e03	-2.55e-07	2.89e-11	-1.18e-15

Fonte: (OLIVEIRA, 2019)

Todas as unidades geradoras possuem os mesmos limites $35MW$ para a potência mínima e $65MW$ para a potência máxima. Além disso, a vazão turbinada de todas as unidades geradores está dentro do limite $[70 - 140]m^3/s$.

Nas tabelas 3, 4 e 5 estão presentes os valores para as vazões afluentes, a demanda energética e a vazão no modo de controle conjunto, respectivamente, para cada uma da UHE's por hora.

Tabela 3 – Vazões Afluentes de cada UHE por hora

Vazões afluentes em m^3/s					
Hora	U1	U2	Hora	U1	U2
0	102.83	208.30	12	341.35	228.87
1	102.65	289.21	13	341.00	114.85
2	103.22	297.96	14	340.62	114.86
3	105.00	192.64	15	340.30	114.87
4	221.29	201.45	16	339.41	114.81
5	223.18	204.59	17	227.74	114.80
6	110.80	218.98	18	236.17	230.89
7	227.00	227.18	19	245.00	229.30
8	114.06	343.05	20	253.80	115.34
9	228.11	343.05	21	376.80	115.33
10	227.75	228.87	22	376.81	109.53
11	227.45	235.15	23	385.52	223.95

Fonte: (OLIVEIRA, 2019)

Tabela 4 – Demanda energética de cada UHE por hora

Demandas de energia em <i>MW</i>					
Hora	U1	U2	Hora	U1	U2
0	330	264	12	292	234
1	330	264	13	300	240
1	330	264	14	292	234
3	322	258	15	300	240
4	322	258	16	292	234
5	330	264	17	292	234
6	330	264	18	420	336
7	330	264	19	437	343
8	300	240	20	437	343
9	292	234	21	437	343
10	292	234	22	437	343
11	292	234	23	445	349

Fonte: (OLIVEIRA, 2019)

Tabela 5 – Vazões no modelo de controle conjunto de cada UHE por hora

Vazões tradicionais no modelo de controle conjuntos em m^3/s					
Hora	U1	U2	Hora	U1	U2
0	705.81	573.59	12	662.67	508.41
1	705.81	573.59	13	662.67	521.45
1	705.81	573.59	14	662.67	508.41
3	686.02	560.56	15	662.67	521.45
4	686.02	560.56	16	662.67	508.41
5	705.81	573.59	17	662.67	508.41
6	705.81	573.59	18	898.30	730.03
7	705.81	573.59	19	934.66	745.24
8	662.67	521.45	20	943.66	745.24
9	662.67	508.41	21	934.66	745.24
10	662.67	508.41	22	934.66	745.24
11	662.67	508.41	23	951.77	758.27

Fonte: (OLIVEIRA, 2019)

4.2.2 Soluções Pareto Combinadas

As figuras 15, 16 e 17 contém as fronteiras Pareto combinadas para cada um dos algoritmos executados em cada uma das fronteiras de Pareto no modelo da usina hidrelétrica em cascata.

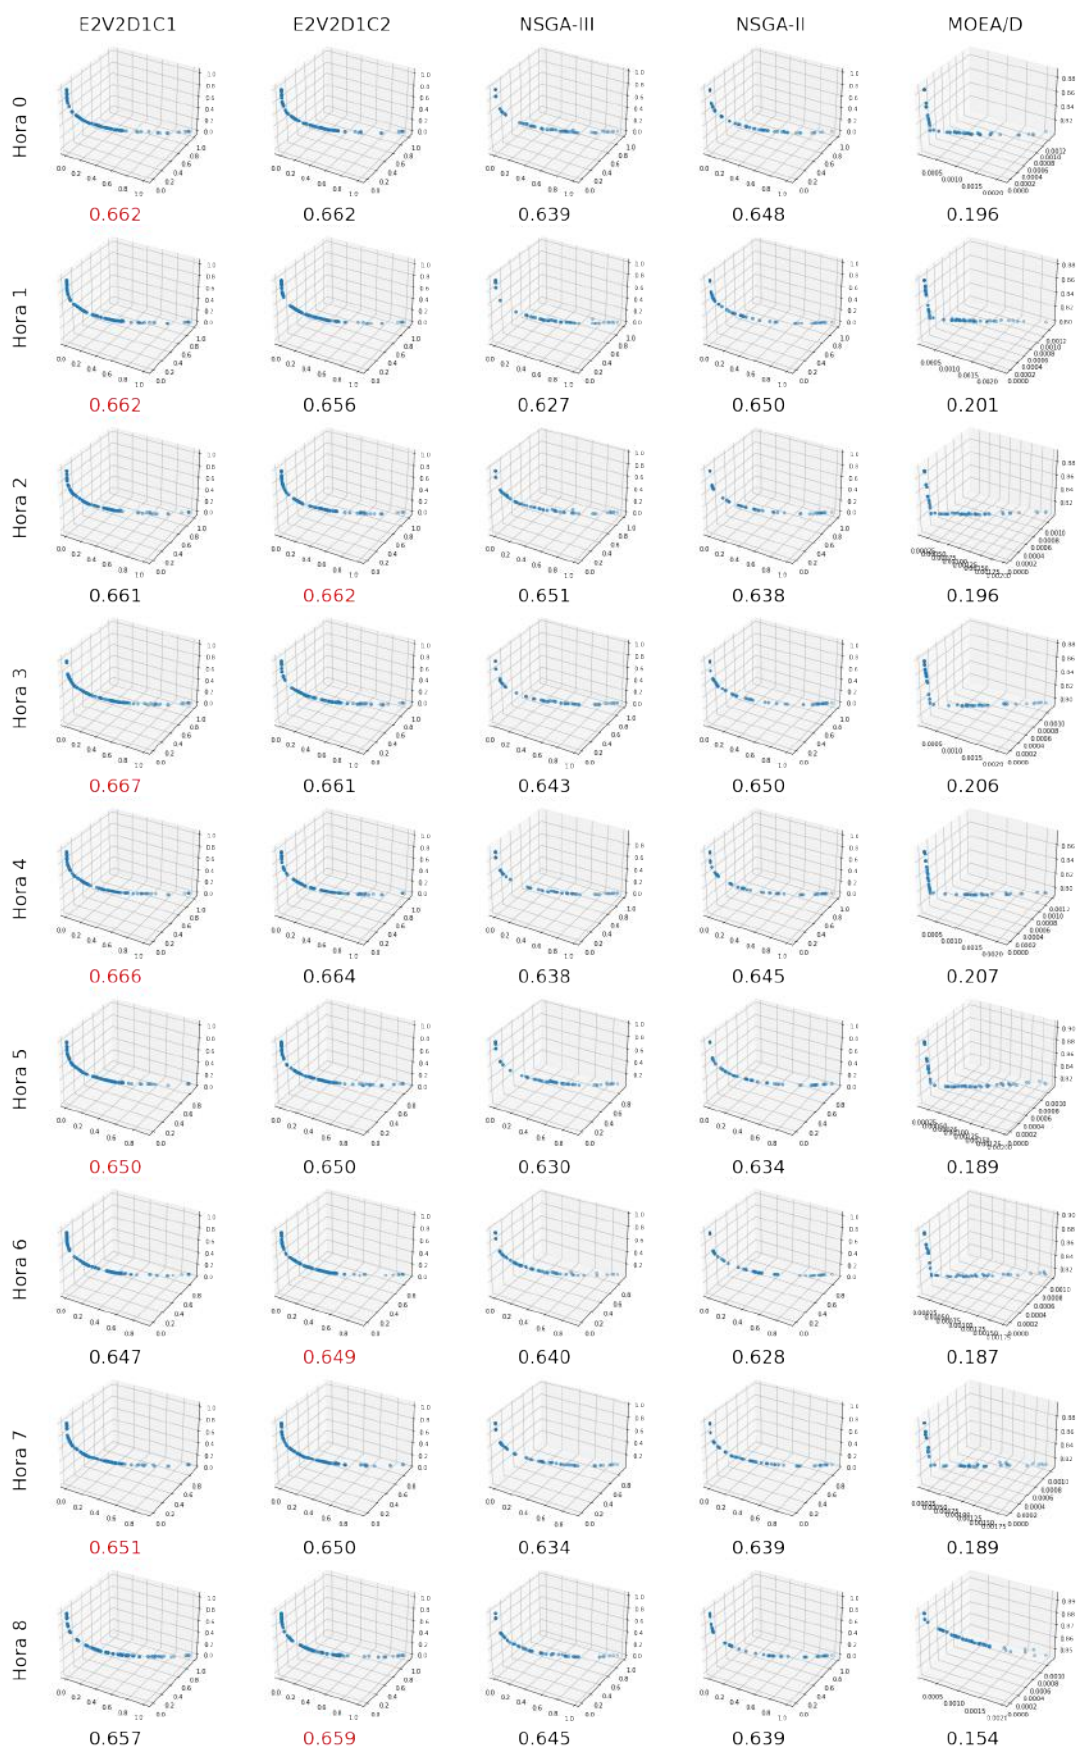
No contexto das Fronteiras Pareto Combinadas, o MOEA/D não teve um desempenho satisfatório, os seus resultados para a métrica de hipervolume são consistentemente menores do que os dos outros algoritmos em todas as horas de operação da Usina Hidrelétrica.

Os melhores resultados para todas as horas, ficaram entre as configurações E2V2D1C1

e E2V2D1C2 do MESH, com certa tendência para a configuração E2V2D1C2 que obteve os maiores resultados para o hipervolume na maioria das horas de operação da UHE.

De forma geral, 4 dos 5 algoritmos foram capazes de encontrar Fronteiras de Pareto consistentes e se mostram eficientes quando aplicados à otimização do modelo em 2.4. Com exceção do MOEA/D, todos os algoritmos aparentam ter bom desempenho em encontrar a fronteira de Pareto para todas as horas de operação da usina hidrelétrica.

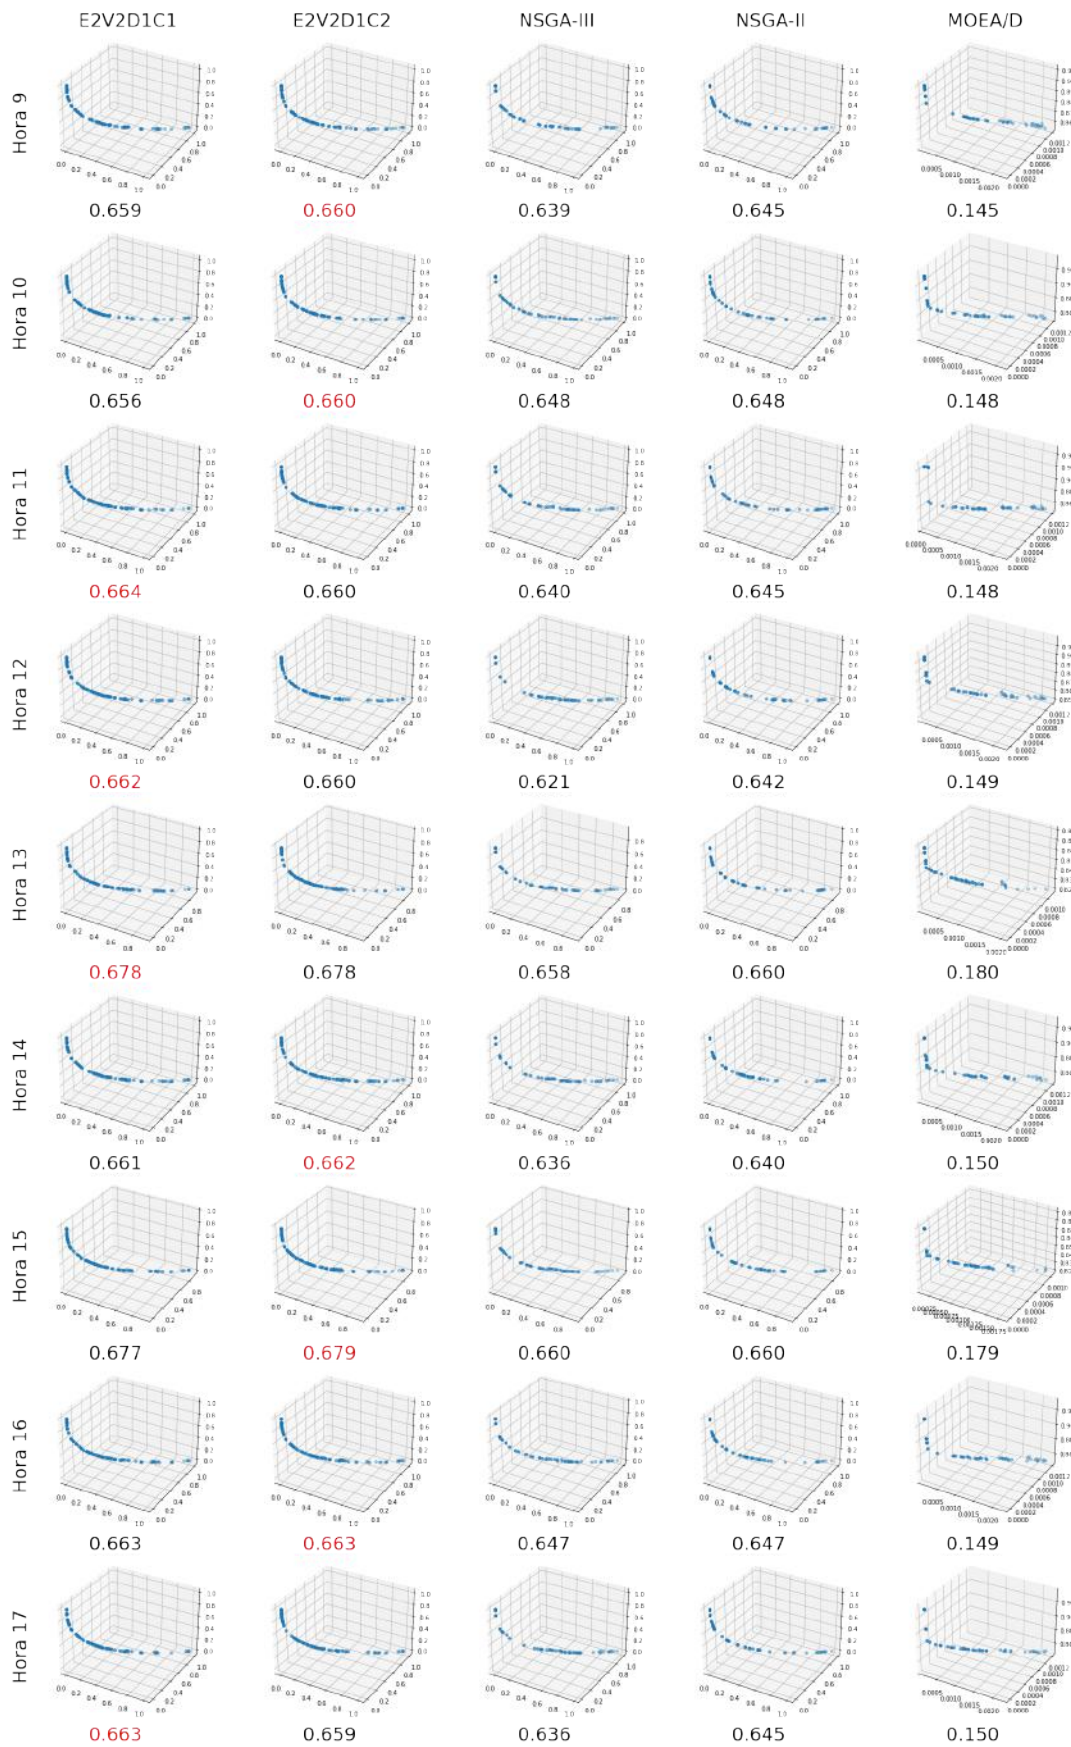
Figura 15 – Gráfico da fronteiras Pareto Combinadas para as horas de 0 a 8



Os valores das funções objetivo foram normalizados para estarem entre 0 e 1

Valores em vermelho indicam os maiores resultados para a Fronteira de Pareto

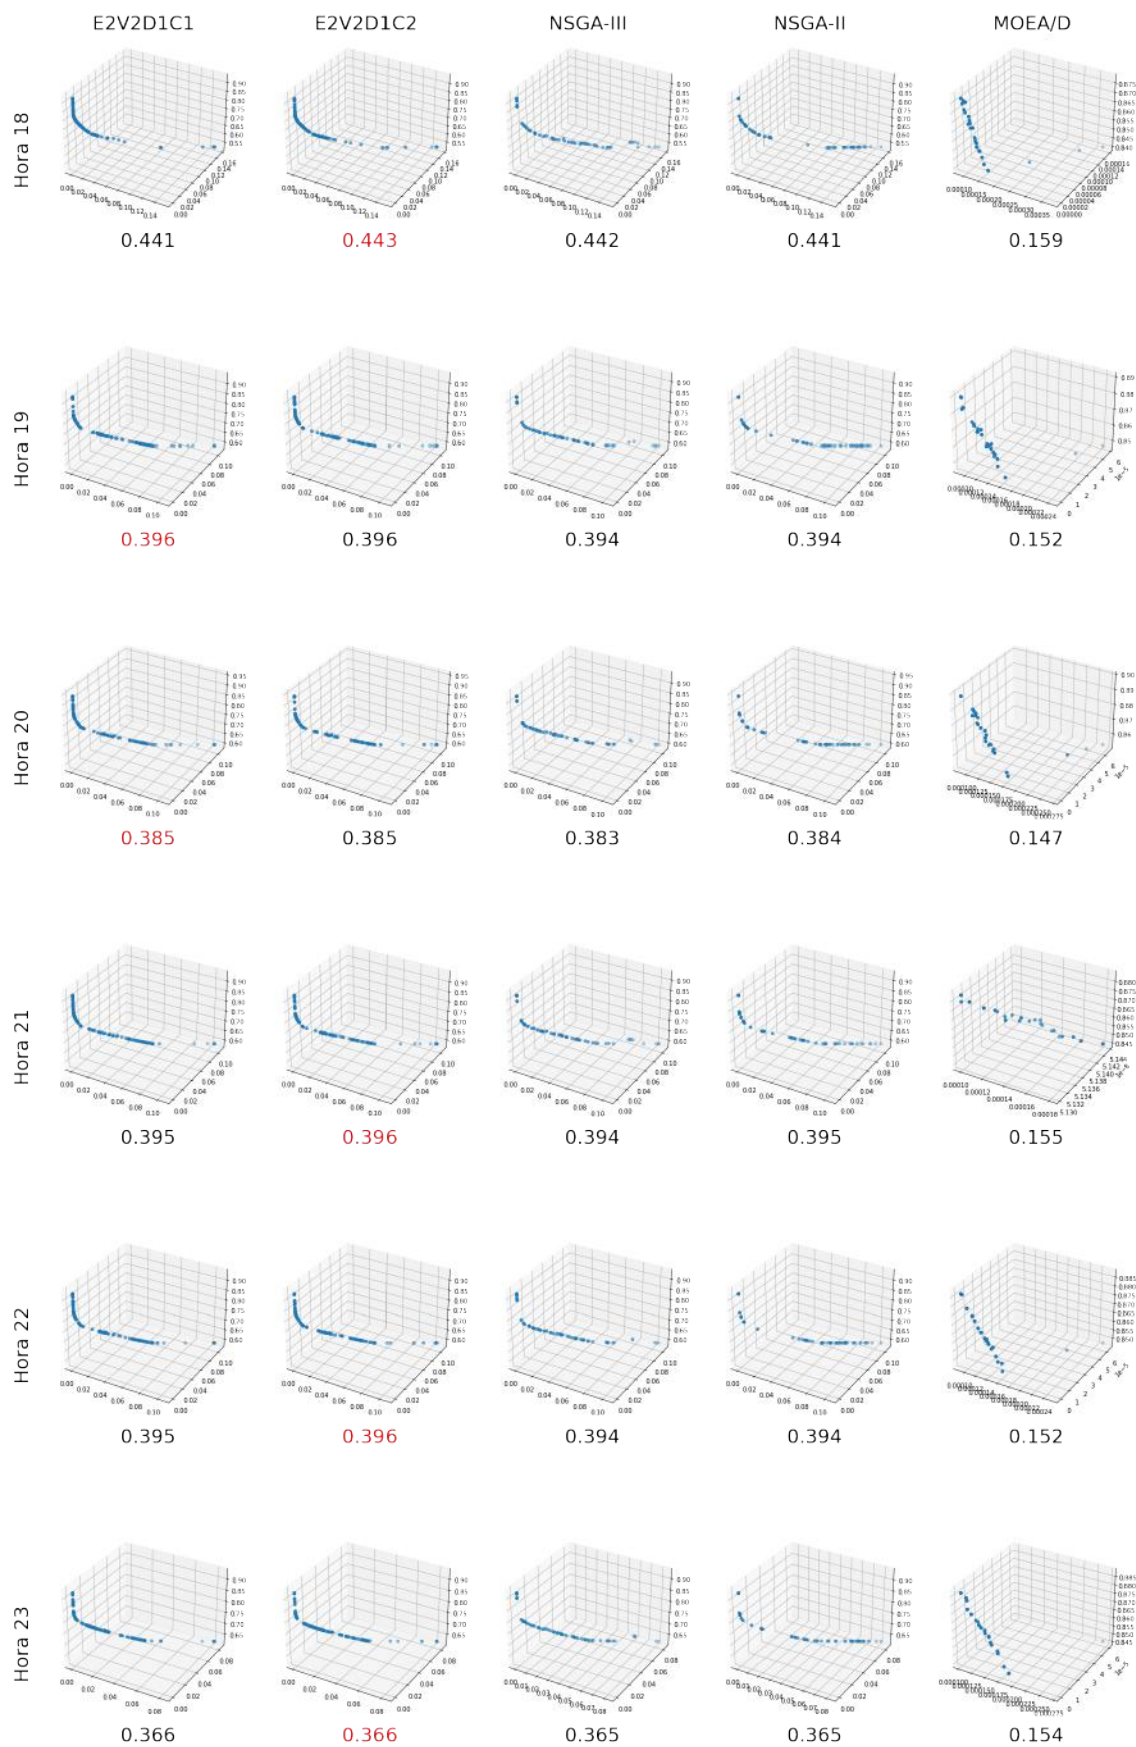
Figura 16 – Gráfico da fronteiras Pareto Combinadas para as horas de 9 a 17



Os valores das funções objetivo foram normalizados para estarem entre 0 e 1

Valores em vermelho indicam os maiores resultados para a Fronteira de Pareto

Figura 17 – Gráfico da fronteiras Pareto Combinadas para as horas de 18 a 23



Os valores das funções objetivo foram normalizados para estarem entre 0 e 1

Valores em vermelho indicam os maiores resultados para a Fronteira de Pareto

4.2.3 Análise Estatística dos Resultados

Os quadros 4 e 5 apresentam as médias e desvios padrão dos hipervolumes em cada uma das horas de execução do despacho elétrico nas UHEs, encontrados em 30 execuções dos algoritmos 5 algoritmos.

De acordo com o quadro 4, a configuração E2V2D1C1 do MESH apresentou os valores mais altos para a média de execuções na maioria das horas de operação, no entanto os seus resultados foram muito próximos dos resultados da configuração E2V2D1C2, de maneira que não foi possível detectar diferença estatísticas entre os dois algoritmos em 17 das 24 horas de operação.

Além dos bons resultados de hipervolume para ambas as configurações do MESH, no quadro 5, é possível perceber que os resultados de desvio padrão de ambas as configurações são consistentemente mais controlados para todas as horas de operação, se comparados com os outros 3 algoritmos que foram avaliados no corrente experimento.

Quadro 4 – Média dos resultados para o hipervolumes de cada um dos algoritmos

	E2V2D1C1	E2V2D1C2	NSGA-III	NSGA-II	MOEA/D
Hora 0	0.6640 (-)	0.6643 (+)	0.6266 (-)	0.6576 (-)	0.1845 (-)
Hora 1	0.6642 (-)	0.6646 (+)	0.6275 (-)	0.6577 (-)	0.1789 (-)
Hora 2	0.6643 (-)	0.6647 (+)	0.6275 (-)	0.6577 (-)	0.1848 (-)
Hora 3	0.6673 (=)	0.6672 (=)	0.6285 (-)	0.6607 (-)	0.1850 (-)
Hora 4	0.6676 (+)	0.6671 (-)	0.6287 (-)	0.6607 (-)	0.1884 (-)
Hora 5	0.6521 (=)	0.6521 (=)	0.6163 (-)	0.6460 (-)	0.1755 (-)
Hora 6	0.6520 (=)	0.6520 (=)	0.6158 (-)	0.6461 (-)	0.1757 (-)
Hora 7	0.6529 (=)	0.6527 (=)	0.6165 (-)	0.6468 (-)	0.1784 (-)
Hora 8	0.6651 (=)	0.6652 (=)	0.6245 (-)	0.6577 (-)	0.1487 (-)
Hora 9	0.6636 (=)	0.6634 (=)	0.6234 (-)	0.6558 (-)	0.1405 (-)
Hora 10	0.6645 (-)	0.6648 (+)	0.6241 (-)	0.6574 (-)	0.1432 (-)
Hora 11	0.6653 (=)	0.6653 (=)	0.6244 (-)	0.6577 (-)	0.1440 (-)
Hora 12	0.6654 (=)	0.6653 (=)	0.6247 (-)	0.6575 (-)	0.1449 (-)
Hora 13	0.6811 (=)	0.6812 (=)	0.6423 (-)	0.6747 (-)	0.1735 (-)
Hora 14	0.6655 (=)	0.6653 (=)	0.6250 (-)	0.6580 (-)	0.1440 (-)
Hora 15	0.6813 (+)	0.6811 (-)	0.6418 (-)	0.6747 (-)	0.1746 (-)
Hora 16	0.6653 (=)	0.6655 (=)	0.6256 (-)	0.6581 (-)	0.1447 (-)
Hora 17	0.6662 (+)	0.6658 (-)	0.6260 (-)	0.6589 (-)	0.1458 (-)
Hora 18	0.4443 (=)	0.4443 (=)	0.4365 (-)	0.4430 (-)	0.1397 (-)
Hora 19	0.3964 (=)	0.3963 (=)	0.3910 (-)	0.3951 (-)	0.1327 (-)
Hora 20	0.3859 (=)	0.3858 (=)	0.3805 (-)	0.3846 (-)	0.1232 (-)
Hora 21	0.3964 (=)	0.3963 (=)	0.3908 (-)	0.3952 (-)	0.1378 (-)
Hora 22	0.3964 (=)	0.3963 (=)	0.3912 (-)	0.3951 (-)	0.1351 (-)
Hora 23	0.3665 (=)	0.3666 (=)	0.3626 (-)	0.3656 (-)	0.1331 (-)

Os valores das funções objetivo foram normalizados para estarem entre 0 e 1

Quadro 5 – Desvio Padrão dos resultados para o hipervolumes de cada um dos algoritmos

	E2V2D1C1	E2V2D1C2	NSGA-III	NSGA-II	MOEA/D
Hora 0	0.000501	0.000633	0.002269	0.000655	0.010703
Hora 1	0.000620	0.000545	0.002844	0.001013	0.014638
Hora 2	0.000683	0.000565	0.002264	0.000905	0.013448
Hora 3	0.000647	0.000581	0.002510	0.000944	0.016649
Hora 4	0.000605	0.000700	0.002546	0.000791	0.013835
Hora 5	0.000378	0.000437	0.002656	0.000819	0.012707
Hora 6	0.000536	0.000467	0.002171	0.000858	0.012570
Hora 7	0.000574	0.000630	0.002812	0.000763	0.012139
Hora 8	0.000702	0.000591	0.001886	0.000951	0.003187
Hora 9	0.000409	0.000529	0.002070	0.000957	0.002983
Hora 10	0.000560	0.000569	0.002463	0.001113	0.004141
Hora 11	0.000575	0.000502	0.002299	0.001069	0.007981
Hora 12	0.000479	0.000737	0.002396	0.001056	0.004984
Hora 13	0.000538	0.000473	0.001401	0.000608	0.004168
Hora 14	0.000585	0.000689	0.002358	0.001068	0.005560
Hora 15	0.000612	0.000521	0.001714	0.000693	0.004348
Hora 16	0.000595	0.000517	0.002471	0.000805	0.005340
Hora 17	0.000436	0.000409	0.002008	0.001129	0.007190
Hora 18	0.000047	0.000058	0.003102	0.000306	0.009085
Hora 19	0.000029	0.000039	0.000974	0.000198	0.008395
Hora 20	0.000027	0.000043	0.000800	0.000264	0.010287
Hora 21	0.000023	0.000029	0.002142	0.000286	0.009521
Hora 22	0.000024	0.000040	0.000754	0.000252	0.007918
Hora 23	0.000022	0.000027	0.000506	0.000236	0.009308

O quadro 6 apresenta os resultados dos P-valores para o teste U de Mann-Whitney. Pela análise de tal, é possível declarar que existe diferença estatística entre os algoritmos NSGA-III, NSGA-II e MOEA/D e o algoritmo mais apto a solucionar o problema de despacho elétrico para cada uma das horas de operação. Enquanto isso, não é possível declarar diferença estatística entre as duas configurações do MESH em 17 das 23 horas, o que indica que ambas as configurações tiveram desempenho similar na solução do problema.

A partir de uma avaliação estatística dos resultados, é possível observar que os resultados do algoritmo MESH se diferenciam estatisticamente, quando comparado com os outros 3 algoritmos testados (NSGA-III, NSGA-II e MOEA/D). Ambas as configurações se mostram mais robustas estatisticamente em todas as horas de operação.

Quadro 6 – P-valores para o Teste U de Mann-Whitney

	E2V2D1C1	E2V2D1C2	NSGA-III	NSGA-II	MOEA/D
Hora 0 (E2V2D1C2)	0.030	-	1.509e-11	1.509e-11	1.509e-11
Hora 1 (E2V2D1C2)	0.003	-	1.509e-11	1.509e-11	1.509e-11
Hora 2 (E2V2D1C2)	0.045	-	1.509e-11	1.509e-11	1.509e-11
Hora 3 (E2V2D1C1)	-	0.241	1.509e-11	1.509e-11	1.509e-11
Hora 4 (E2V2D1C1)	-	0.003	1.509e-11	1.509e-11	1.509e-11
Hora 5 (E2V2D1C1)	-	0.491	1.509e-11	1.509e-11	1.509e-11
Hora 6 (E2V2D1C2)	0.491	-	1.509e-11	1.509e-11	1.509e-11
Hora 7 (E2V2D1C1)	-	0.197	1.509e-11	1.509e-11	1.509e-11
Hora 8 (E2V2D1C2)	0.380	-	1.509e-11	1.509e-11	1.509e-11
Hora 9 (E2V2D1C1)	-	0.125	1.509e-11	1.509e-11	1.509e-11
Hora 10 (E2V2D1C2)	0.031	-	1.509e-11	1.509e-11	1.509e-11
Hora 11 (E2V2D1C1)	-	0.555	1.509e-11	1.509e-11	1.509e-11
Hora 12 (E2V2D1C1)	-	0.353	1.509e-11	1.509e-11	1.509e-11
Hora 13 (E2V2D1C2)	0.461	-	1.509e-11	1.509e-11	1.509e-11
Hora 14 (E2V2D1C1)	-	0.114	1.509e-11	1.509e-11	1.509e-11
Hora 15 (E2V2D1C1)	-	0.039	1.509e-11	1.509e-11	1.509e-11
Hora 16 (E2V2D1C2)	0.100	-	1.509e-11	1.509e-11	1.509e-11
Hora 17 (E2V2D1C1)	-	9.290e-4	1.509e-11	1.509e-11	1.509e-11
Hora 18 (E2V2D1C1)	-	0.299	1.509e-11	1.509e-11	1.509e-11
Hora 19 (E2V2D1C1)	-	0.122	1.509e-11	1.509e-11	1.509e-11
Hora 20 (E2V2D1C1)	-	0.054	1.509e-11	1.509e-11	1.509e-11
Hora 21 (E2V2D1C1)	-	0.068	1.509e-11	1.509e-11	1.509e-11
Hora 22 (E2V2D1C1)	-	0.076	1.509e-11	1.509e-11	1.509e-11
Hora 23 (E2V2D1C2)	0.449	-	1.509e-11	1.509e-11	1.509e-11

Valores muito próximos de 0 são truncados para 1.509e-11

4.2.4 Observações Finais

Assim como observado nos problemas de teste, as configurações do MESH apresentaram os menores desvios padrão dentre todos os algoritmos. Tais resultados podem indicar um comportamento comum do MESH em relação ao desvio padrão que pode ser melhor avaliado em futuros trabalhos

Não é possível declarar a melhor das configurações do MESH para o problema da usina, uma vez que para a maioria das horas de execução não houve diferença estatística entre as duas configurações, no entanto, é evidente a robustez do desempenho de MESH (ambas as versões) frente aos outros 3 métodos avaliados.

Como visto em (OLIVEIRA, 2019) e (MARCELINO et al., 2021), onde a mesma modelagem da usina foi implementada, porém com 2 funções objetivo, todos os algoritmos falhavam em encontrar a Fronteira de Pareto para as últimas horas de operação. As Fronteiras de Pareto encontradas por 4 dos 5 algoritmos, revelam que a adição da terceira função objetivo causou melhoria nos resultados.

5 CONCLUSÃO

Neste trabalho, foi analisado o desempenho de diferentes meta-heurísticas evolutivas na solução de problemas multi-objetivo, fornecendo uma atenção especial ao algoritmo MESH (OLIVEIRA, 2019) que teve como adição uma alternativa para o seu operador de distância de multidões, o *Special Crowding Distance* (YUE et al., 2021) e que nunca antes havia sido testado em problemas com 3 objetivos.

De acordo com os resultados nas funções de teste DTLZ (DEB et al., 2002b), o MESH se mostrou competitivo em comparação com outros algoritmos, o que indica certo sucesso em resolver problemas com 3 funções objetivo.

Além disso, o modelo matemático, proposto em (OLIVEIRA, 2019), para a geração de energia de uma usina em cascata, foi acrescido de uma função objetivo, referente à distância entre o fluxo de água otimizado e o fluxo de água no modo de controle conjunto.

Como foi visto na seção 4.2, 4 dos 5 algoritmos foram capazes de encontrar Fronteiras de Pareto consistentes para todas as horas de operação da usina, em contraste com o que foi apresentado em (OLIVEIRA, 2019) e (MARCELINO et al., 2021), quando o problema foi implementado com 2 funções objetivo e os algoritmos falhavam em encontrar soluções consistentes para as horas finais de operação.

Os resultados mostram que os desvios padrão do MESH no modelo matemático das UHE's em cascata, foram inferiores ao dos outros algoritmos testados, assim como foi visto na família de problemas de teste DTLZ. A característica de baixa variância nos hipervolumes das fronteiras encontradas pelo MESH é um potencial estudo para trabalhos futuros, tais como:

1. Realizar um estudo de ajuste fino de parâmetros para a nova versão do algoritmo MESH aqui apresentada e;
2. Realizar experimentos computacionais com outras famílias de função de teste.

Descritos na seção 1.3, os objetivos deste trabalho envolviam testar o desempenho do algoritmo MESH em problemas com 3 objetivos, a implementação de um operador alternativo de distância de multidões, aplicação de métodos evolutivos em um problema prático de geração de energia e a adição da terceira função objetivo no modelo matemático das UHE's em cascata. É possível dizer que o trabalho foi bem sucedido na execução de todos os seus objetivos, uma vez que todos eles puderam ser cumpridos e compilados nesta monografia.

REFERÊNCIAS

- AUDET, C. et al. Performance indicators in multiobjective optimization. **European Journal of Operational Research**, v. 292, n. 2, p. 397–422, 2021. ISSN 0377-2217.
- Blank, J.; Deb, K. pymoo: Multi-objective optimization in python. **IEEE Access**, v. 8, p. 89497–89509, 2020.
- COLLETTE, P. S. Y. **Multiobjective Optimization: Principles and Case Studies**. [S.l.]: Springer, 2004.
- DEB, K.; JAIN, H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part i: Solving problems with box constraints. **IEEE Transactions on Evolutionary Computation**, v. 18, n. 4, p. 577–601, 2014.
- DEB, K.; KALYANMOY, D. **Multi-Objective Optimization Using Evolutionary Algorithms**. USA: John Wiley & Sons, Inc., 2001. ISBN 047187339X.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. **IEEE Transactions on Evolutionary Computation**, v. 6, n. 2, p. 182–197, 2002.
- DEB, K. et al. Scalable multi-objective optimization test problems. **Proc. of 2002 IEEE Congress on Evolutionary Computation**, v. 1, p. 825–830, 06 2002.
- FERNANDES, J. P. T. Abordagem lexicográfica na otimização da operação de usinas hidrelétricas. **UNICAMP**, 2015. Tese (Doutorado).
- IZMAILOV, M. V. S. A. F. **Otimização Vol. 1**. 4. ed. Rio de Janeiro: IMPA, 2020.
- JAIN, H.; DEB, K. An evolutionary many-objective optimization algorithm using reference-point based nondominated sorting approach, part ii: Handling constraints and extending to an adaptive approach. **IEEE Transactions on Evolutionary Computation**, v. 18, n. 4, p. 602–622, 2014.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. **Proceedings of ICNN'95 - International Conference on Neural Networks**, v. 4, p. 1942–1948 vol.4, 1995.
- LANSBERRY, J.; WOZNIAK, L. Adaptive hydrogenerator governor tuning with a genetic algorithm. **IEEE Transactions on Energy Conversion**, v. 9, n. 1, p. 179–185, 1994.
- LANSBERRY, J.; WOZNIAK, L.; GOLDBERG, D. Optimal hydrogenerator governor tuning with a genetic algorithm. **IEEE Transactions on Energy Conversion**, v. 7, n. 4, p. 623–630, 1992.
- MACULAN, M. H. C. F. N. **Otimização Linear**. Brasília: editora UnB, 2004.
- MANN, H. B.; WHITNEY, D. R. On a Test of Whether one of Two Random Variables is Stochastically Larger than the Other. **The Annals of Mathematical Statistics**, Institute of Mathematical Statistics, v. 18, n. 1, p. 50 – 60, 1947.

- MARCELINO, C. et al. Applying c-deepso to solve large scale global optimization problems. **2018 IEEE Congress on Evolutionary Computation (CEC)**, p. 1–6, 2018.
- MARCELINO, C. G. Uma abordagem evolutiva e híbrida para a solução de problemas de fluxo de potência Ótimo. **CEFET-MG**, 2017. Tese (Doutorado).
- MARCELINO, C. G. et al. Dynamic electric dispatch for wind power plants: A new automatic controller system using evolutionary algorithms. **Sustainability**, v. 13, n. 21, 2021. ISSN 2071-1050. Disponível em: <https://www.mdpi.com/2071-1050/13/21/11924>.
- MARCELINO, C. G. et al. Application of evolutionary multiobjective algorithms for solving the problem of energy dispatch in hydroelectric power plants. **Evolutionary Multi-Criterion Optimization**, Springer International Publishing, Cham, p. 403–417, 2015.
- MARCELINO, C. G. et al. An efficient multi-objective evolutionary approach for solving the operation of multi-reservoir system scheduling in hydro-power plants. **Expert Systems With Applications**, abs/2107.09718, 2021. Disponível em: <https://arxiv.org/abs/2107.09718>.
- MIRANDA, V.; FONSECA, N. Epso - best-of-two-worlds meta-heuristic applied to power system problems. **Proceedings of the 2002 Congress on Evolutionary Computation.**, v. 2, p. 1080–1085 vol.2, 2002.
- OLIVEIRA, L. B. Desenvolvimento de um algoritmo multiobjetivo híbrido: Estudo de caso na geração de energia com usinas hidroelétricas em cascata. **CEFET-MG**, 2019. Tese (Mestrado).
- ONS. **Carga e Geração de Energia Agora**. 2022. https://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspx.
- STORN, R.; PRICE, K. Differential evolution – a simple and efficient heuristic for global optimization over continuous spaces. **Journal of Global Optimization**, Kluwer Academic Publishers, USA, v. 11, n. 4, p. 341–359, dec 1997. ISSN 0925-5001. Disponível em: <https://doi.org/10.1023/A:1008202821328>.
- TAKAHASHI, A. G.-C. e. C. A. R. **Manual de computação evolutiva e metaheurística**. [S.l.]: editora UFMG, 2012. DOI: <http://dx.doi.org/10.14195/978-989-26-0583-8>.
- YUE, C. et al. Differential evolution using improved crowding distance for multimodal multiobjective optimization. **Swarm and Evolutionary Computation**, v. 62, p. 100849, 2021. ISSN 2210-6502. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2210650221000109>.
- ZHANG, Q.; LI, H. Moea/d: A multiobjective evolutionary algorithm based on decomposition. **IEEE Transactions on Evolutionary Computation**, v. 11, n. 6, p. 712–731, 2007.