

UNIVERSIDADE FEDERAL DO PARANÁ

JHONYS LEITE DE OLIVEIRA

ESTIMAÇÃO DE PARÂMETROS PARA REGULADOR DE VELOCIDADE DE USINA
HIDRELÉTRICA UTILIZANDO ALGORITMOS DE OTIMIZAÇÃO EVOLUÇÃO
DIFERENCIAL E OTIMIZAÇÃO DE LOBOS CINZENTOS

CURITIBA

2018

JHONYS LEITE DE OLIVEIRA

ESTIMAÇÃO DE PARÂMETROS PARA REGULADOR DE VELOCIDADE DE
USINA HIDRELÉTRICA UTILIZANDO ALGORITMOS DE OTIMIZAÇÃO
EVOLUÇÃO DIFERENCIAL E OTIMIZAÇÃO DE LOBOS CINZENTOS

Dissertação apresentada ao curso de Pós-Graduação em Engenharia Elétrica, Área de Concentração Sistemas Eletrônicos, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Gideon Villar Leandro

Co Orientador: Prof. Dr. Marlio José do Couto Bonfim

CURITIBA

2018

FICHA CATALOGRÁFICA ELABORADA PELO SISTEMA DE BIBLIOTECAS/UFPR
BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

OL48e

Oliveira, Jhonys Leite de

Estimação de parâmetros para regulador de velocidade de usina hidrelétrica utilizando algoritmos de otimização evolução diferencial e otimização de lobos cinzentos / Jhonys Leite de Oliveira. – Curitiba, 2018.

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, 2018.

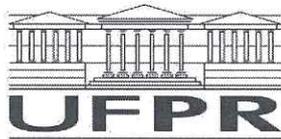
Orientador: Gideon Villar Leandro.

Coorientador: Marlio José do Couto Bonfim.

1. Estimação de parâmetros. 2. Modelos matemáticos. 3. Evolução diferencial. 4. Usina hidrelétrica. I. Universidade Federal do Paraná. II. Leandro, Gideon Villar. III. Bonfim, Marlio José do Couto. IV. Título.

CDD: 518.1

Bibliotecária: Romilda Santos - CRB-9/1214



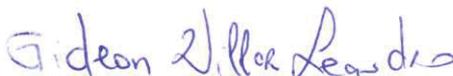
MINISTÉRIO DA EDUCAÇÃO
SETOR TECNOLOGIA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
ELÉTRICA

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **JHONYS LEITE DE OLIVEIRA** intitulada: **ESTIMAÇÃO DE PARÂMETROS PARA REGULADOR DE VELOCIDADE DE USINA HIDREL ETRICA UTILIZANDO ALGORITMOS DE OTIMIZAÇÃO EVOLUÇÃO DIFERENCIAL E OTIMIZAÇÃO DE LOBOS CINZENTOS**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 29 de Maio de 2018.


GIDEON VILLAR LEANDRO

Presidente da Banca Examinadora (UFPR)


MANUEL MARTÍN PÉREZ REIBOLD
Avaliador Externo (UNIJUI)


ROMAN KUIAVA
Avaliador Interno (UFPR)


EDUARDO PARENTE RIBEIRO
Avaliador Interno (UFPR)

AGRADECIMENTOS

Minha família sempre foi e continua sendo, muito presente em minha vida, todos meus desafios e conquistas foram com eles ao meu lado, me incentivando, dando forças, ensinando a sempre ser perseverante e me ensinando para cada vez melhorar para ser uma boa pessoa para contribuir com a nossa sociedade. Meus pais e avós abdicaram de muitas realizações pessoais para dar todo o suporte e amor para mim e meu irmão, sei que sem minha família, eu não conseguiria chegar aonde estou, por isso eu sou eternamente grato ao meu pai Isaac de Oliveira, minha mãe Marli Leite de Oliveira, meu irmão Jean Leite de Oliveira, meus avós Francisca da Rocha Fidelis, José Fidelis Leite, Eulálio Manuel de Oliveira, Josefa Pereira de Oliveira e meus demais familiares, saibam que eu tenho enorme orgulho e os amo demais.

Agradeço ao Prof. Dr. Gideon Villar Leandro e o Prof. Dr. Marlio José do Couto Bonfim por terem me aceitado de braços aberto e sempre a disposição para compartilhar seu valioso conhecimento, cresci muito ao decorrer desse vivência que tivemos, com seus apontamentos e ensinamentos, vindos desses grandes profissionais.

Agradeço ao Prof. Dr. Luiz Antônio Pereira Neves por ter proporcionado diversas oportunidades e parcerias, é um grande profissional e amigo.

Agradeço ao Prof. MSc. Amarildo Geraldo Reichel por ter sido muito presente, me acompanhando desde o início da graduação, orientando nos projetos de iniciação científica e vários outros, foi uma pessoa que marcou muito na minha graduação e se tornou muito importante para mim, como um segundo pai.

Agradeço a Deus e a Jesus, por me proporcionar todas essas oportunidades e forças para sempre manter-se focado e inspirado para obter mais conhecimento a cada dia.

O presente trabalho foi contemplado com bolsa de estudos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES/CNPq - Brasil).

RESUMO

O modelo matemático é, sem dúvida, o modelo mais versátil e barato que um cientista pode usar, uma vez que diferentes variações nas características e entradas de um sistema podem ser testadas, analisadas e aprimoradas sem a necessidade de implementação física. A teoria da identificação de sistemas é uma técnica desenvolvida com objetivo de obter bons modelos matemáticos a partir de dados experimentais. A estimação de parâmetros é considerada uma etapa fundamental na identificação de sistemas, é um procedimento no qual o objetivo é minimizar uma função de erro (diferença entre uma variável temporal do sistema e do modelo). Esta minimização está diretamente ligada aos valores dos parâmetros encontrados pelo método utilizado. Neste trabalho são utilizadas duas metaheurísticas, o algoritmo de otimização dos Lobos Cinzentos (GWO), e o algoritmo de otimização da Evolução Diferencial (ED) para a estimação de parâmetros de sistemas não lineares. Estes dois algoritmos são implementados de forma mono-objetivo e multi-objetivo. Na forma mono-objetivo, os parâmetros são estimados considerando a entrada e a saída do sistema, necessitando minimizar apenas uma função objetivo. Já na forma multi-objetivo, os parâmetros são estimados considerando apenas uma entrada e uma saída, porém há necessidade de minimizar várias funções objetivo. Estas metaheurísticas são inicialmente utilizadas em três funções testes para sua validação, e obtém os resultados reportados pela literatura. Depois elas são utilizadas no regulador de velocidade de uma usina hidrelétrica, que faz parte do Sistema Interligado Nacional (SIN), sendo inicialmente estimados os parâmetros de cada malha de forma mono-objetivo, depois estima-se todos os parâmetros utilizando a forma multi-objetivo. Os resultados obtidos mostram que ambos algoritmos e ambas as formas obtém soluções que levam os modelos a terem suas respostas similares aos dados obtidos em campo.

Palavras-chave: Estimação de parâmetros, Otimizador de Lobos Cinzentos, Evolução Diferencial, Usina Hidrelétrica.

ABSTRACT

The mathematical model is undoubtedly the most versatile and inexpensive model that a scientist can use, since different variations on the characteristics and inputs of a system can be tested, analyzed and improved without the need for physical implementation. The theory of system identification is a technique developed to obtain good mathematical models from experimental data. The estimation of parameters is considered a fundamental step in the identification of systems, it is a procedure in which the objective is to minimize an error function (difference between a system and model of time variable). This minimization is directly linked to the values of the parameters found by the method used. In this work, two metaheuristics, the Grey Wolf Optimization Algorithm (GWO), and the Differential Evolution algorithm (DE) are used for the estimation of nonlinear system parameters. These two algorithms are implemented in a mono-objective and multi-objective. In the mono-objective, the parameters are estimated considering the input and output of the system, needing to minimize only one objective function. In multi-objective, the parameters are estimated considering only one input and one output, but there is a need to minimize several objective functions. These metaheuristics are initially used in three test functions for validation, and obtain the results reported in the literature. Then are used in the speed regulator of a hydroelectric plant, which belongs of the National Inter-connected System, initially estimated the parameters of each mesh in a mono-objective algorithm, then it is estimated all of the parameters using the multi-objective algorithm. The obtained results show that both algorithms in multi-objective and mono-objective, can get solutions that take the models to have their answers similar to the data obtained in the field.

Keywords: Parameter estimation, Grey Wolf Optimizer, Differential Evolution, Hydroelectric Power Plant.

LISTA DE FIGURAS

1.1	Ramificação da classificação de alguns métodos de otimização.	14
2.1	Sistema de geração hidrelétrica.	20
2.2	Controlador atual da usina.	21
2.3	Amplificador hidráulico.	22
2.4	Conjunto microprocessado.	23
2.5	Válvula piloto.	23
2.6	Válvula distribuidora.	24
2.7	Distribuidor.	25
3.1	Fluxograma do algoritmo de Evolução Diferencial.	30
3.2	Mutação Diferencial.	33
3.3	Fluxograma Otimizador Lobos Cinzentos.	38
3.4	Hierarquia de liderança.	39
3.5	Seleção de ataque ou busca da presa.	41
3.6	Fluxograma do Lobos Cinzentos Multiobjetivo.	43
4.1	Gráfico da função de Ackley de $n = 2$	45
4.2	MSE dos algoritmos DE e GWO para função de Ackley, dimensão = 50 . .	46
4.3	MSE dos algoritmos DE e GWO para a função de Ackley, dimensão = 50 .	47
4.4	MSE dos algoritmos DE e GWO para função de Ackley, dimensão = 500 .	47
4.5	MSE dos algoritmos DE e GWO para a função de Ackley, dimensão = 500	48
4.6	MSE dos algoritmos DE e GWO para uma execução com iteração = 1000 e dimensão = 50, da função de Ackley	48
4.7	MSE dos algoritmos DE e GWO para uma execução com iteração = 1000 e dimensão = 50, da função de Ackley	49
4.8	Gráfico da função de Griewank de $n = 2$	50
4.9	MSE dos algoritmos DE e GWO para função de Griewank, dimensão = 50	51

4.10	MSE dos algoritmos DE e GWO para a função de Griewank, dimensão = 50	51
4.11	Gráfico da função de Spheref de $n = 2$	52
4.12	MSE dos algoritmos DE e GWO para função de Spheref, dimensão = 50	53
4.13	MSE dos algoritmos DE e GWO para a função de Spheref, dimensão = 50	53
4.14	Resultados da tensão controlador. a) DE mono objetivo, b) GWO mono objetivo, c) DE multiobjetivo, d) GWO multiobjetivo	56
4.15	Resultados mono objetivos da Tensão do Controlador	57
4.16	Resultados multiobjetivos da Tensão do Controlador	57
4.17	Resultados da válvula proporcional. a) DE mono objetivo, b) GWO mono objetivo, c) DE multiobjetivo, d) GWO multiobjetivo	58
4.18	Resultados mono objetivos da Válvula Proporcional	59
4.19	Resultados multiobjetivos da Válvula Proporcional	59
4.20	Resultados da válvula distribuidora. a) DE mono objetivo, b) GWO mono objetivo, c) DE multiobjetivo, d) GWO multiobjetivo	60
4.21	Resultados mono objetivos da Válvula Distribuidora	61
4.22	Resultados multiobjetivos da Válvula Distribuidora	61
4.23	Resultados do distribuidor. a) DE mono objetivo, b) GWO mono objetivo, c) DE multiobjetivo, d) GWO multiobjetivo	62
4.24	Resultados mono objetivos do Distribuidor	63
4.25	Resultados multiobjetivos do Distribuidor	63
4.26	Parâmetros estimados com DE	64
4.27	Parâmetros estimados com GWO	64
4.28	Parâmetros estimados com MODE	65
4.29	Parâmetros estimados com MOGWO	65
4.30	MSE de todas as funções, gerado com DE	66
4.31	MSE de todas as funções, gerado com GWO	66
4.32	MSE de todas as funções, gerado com MODE	67
4.33	MSE de todas as funções, gerado com MOGWO	67

SUMÁRIO

1	INTRODUÇÃO.....	12
1.1	Trabalhos Relacionados	16
1.2	Motivação e Justificativa	17
1.3	Objetivo Geral.....	18
1.3.1	Objetivos Específicos.....	18
1.4	Estrutura da Dissertação	18
2	SISTEMA DE CONTROLE DE VELOCIDADE DE UMA USINA HIDRELÉTRICA (UHE)	20
2.1	Modelo matemático do regulador de velocidade	21
2.1.1	Controlador	21
2.1.2	Amplificador Hidráulico.....	22
2.2	Formulação matemática para a estimação dos parâmetros.....	25
2.2.1	Coleta de dados.....	26
2.2.2	Estrutura e representação do modelo.....	26
2.2.3	Estimação de parâmetros.....	26
2.2.4	Validação do modelo.....	27
3	METAHEURÍSTICAS.....	29
3.1	Evolução Diferencial Mono Objetiva.....	30
3.1.1	Inicialização	30

3.1.2	Mutação	31
3.1.3	Cruzamento	33
3.1.4	Seleção	34
3.1.5	Convergência	34
3.2	Evolução Diferencial Multi Objetiva	35
3.3	Otimizador Lobos Cinzentos Mono Objetivo	37
3.3.1	Hierarquia de Liderança	38
3.3.2	Cercar a presa	39
3.3.3	Caçar	40
3.3.4	Atacar presa	41
3.3.5	Buscar presa	41
3.4	Otimizador Lobos Cinzentos Multi Objetivo	42
4	RESULTADOS	44
4.1	Funções de Avaliação - Benchmark	45
4.1.1	Função de Benchmark Ackley	45
4.1.2	Função de Benchmark Greiwank	49
4.1.3	Função de Benchmark Spheref	52
4.2	Resultados com algoritmos Mono e Multiobjetivo de evolução diferencial e lobos cinzentos	54
4.2.1	Parâmetros do controlador	56
4.2.2	Parâmetros da Válvula proporcional	58

4.2.3 Parâmetros da Válvula distribuidora.....	60
4.2.4 Parâmetros do Distribuidor	62
4.3 Análise dos parâmetros estimados.....	63
5 CONCLUSÃO.....	71
REFERÊNCIAS.....	72

1 INTRODUÇÃO

Em muitos problemas de engenharia, deseja-se entender, prever e controlar o sistema sob estudo. Para esse fim, a comunidade científica faz uso de modelos matemáticos intensamente, porque isso permite a simulação do sistema no computador. Desta forma, podem-se ajustar controladores e/ou estudar formas de melhorar o desempenho do sistema por meio da simulação.

A teoria da identificação de sistemas foi desenvolvida para abordar a necessidade de métodos para obter modelos matemáticos a partir de dados experimentais. No entanto, para muitos engenheiros e cientistas, a tarefa de modelagem é apenas um passo intermediário para a solução de seus problemas.

As principais etapas levadas em conta na identificação de um sistema são: dados, modelo, função de custo, estimação/ajuste dos parâmetros. Os demais aspectos técnicos em geral são irrelevantes para a qualidade da estimativa. Os métodos numéricos utilizados para minimizar a função de custo, problemas de condicionamento numérico, parametrizações do modelo e outros são exemplos de escolhas muito importantes que devem ser devidamente abordadas para obter estimativas de parâmetros confiáveis (PINTELO; SCHOUKENS, 2012).

Resumidamente, tem-se que o objetivo do processo de identificação é selecionar um modelo matemático e ajustar os parâmetros deste modelo de modo que a “distância” entre a saída do modelo e os dados se torne tão pequena quanto possível. Essa distância é medida pela função de custo que é minimizada (LJUNG, 1987).

Desta forma, o problema de ajustar os parâmetros do modelo (estimação de parâmetros), pode ser visto como um problema de otimização, ou seja, obter os parâmetros do modelo, com os quais a saída gerada pelo modelo torne-se similar a saída do sistema real cuja saída é obtida de dados de campo (LJUNG; GLAD, 2016).

Otimização é um processo com o foco na obtenção do melhor valor de uma grandeza, de acordo com análise do comportamentos e características da função. Visando a obtenção

da melhor configuração de parâmetros de um processo matemático ou experimental sem testar todas as possibilidades (ARROYO, 2002).

Geralmente, o problema de otimização procura maximizar ou minimizar uma função objetiva de n variáveis de projeto, podendo existir restrições de igualdade e desigualdade, além de limites do espaço de busca (BILLINGS, 2013). No entanto, um problema de otimização pode ter várias soluções, ou seja, a junção de diferentes parâmetros gerados podem gerar os mesmos resultados e o critério da escolha da solução ideal é realizado pelas restrições.

Dessa forma engenheiros, desenvolvedores, pesquisadores e demais profissionais dessas áreas necessitam de métodos de otimização robustos e eficientes para resolver os problemas do seu dia a dia que por vezes demandam alta complexidade e com muitas restrições, mas também necessitam uma ferramenta que não seja tão complexa para resolver o problema, pois inviabilizaria seu uso.

Há uma vasta variedade de métodos de otimização contando cada um com sua forma de obter melhores resultados dependendo da característica do problema definido, sendo assim, a escolha do método depende principalmente do comportamento da peculiaridade que o representa.

Diante das características dos problemas, as ferramentas de otimização são classificadas em dois grupos chamados de programação linear e programação não-linear. Além disso, métodos de otimização podem ser classificados em determinísticos e naturais como ilustrado na Figura 1.

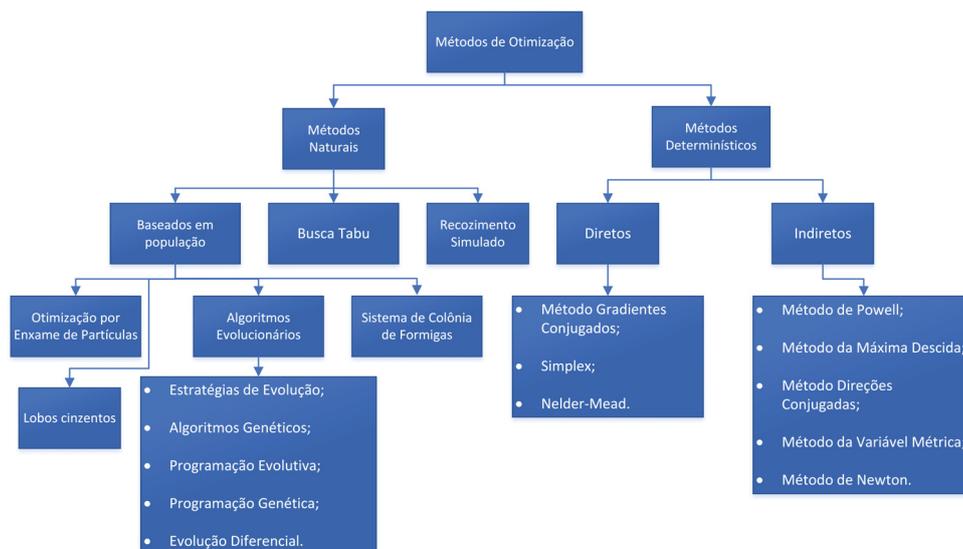


Figura 1.1: Ramificação da classificação de alguns métodos de otimização.

Fonte: (OLIVEIRA et al., 2017)

Os algoritmos metaheurísticos, também chamados de métodos naturais, correspondem a um conjunto de mecanismos de gerenciamento que atua sobre métodos heurísticos. Uma vertente da metaheurística são os algoritmos evolucionários ou também conhecido como computação evolutiva. Sua estrutura se inspira em princípios da teoria da evolução, seleção natural e utiliza modelos destes processos naturais para solucionar problemas de otimização e estimação de parâmetros. Entre as técnicas dos algoritmos evolucionários, destacam-se os algoritmos genéticos (AG), programação evolutiva (PE), estratégias evolucionárias (EE), programação genética (PG) e recozimento simulado (Simulated Annealing), em (EDITORS et al., 2008) e (HAUPT et al., 2004).

De acordo com (OLIVEIRA, 2006), os algoritmos evolucionários se caracterizam por buscar a melhor solução gerando conjuntos de candidatos aleatórios, mas seguindo um comportamento probabilístico, trabalhando de forma aleatória mas orientada ao objetivo de otimizar. Tais métodos utilizam apenas as informações da função de otimização, não utilizando informações sobre possíveis descontinuidades e derivadas. Os algoritmos evolucionários acompanham a seguinte estrutura:

- Gerar aleatoriamente uma população de soluções candidatas;

- Caso o critério de parada não seja satisfeito:
 1. Recombinar alguns indivíduos da população;
 2. Executar mutação entre alguns indivíduos da população;
 3. Analisar o grupo de soluções candidatas;
 4. Determinar um critério para quais soluções irão para a próxima geração.

Mesmo sendo algoritmos concebidos na década de 1990, vêm atualmente ganhando maior popularidade e viabilidade devido à evolução dos computadores e aumento do potencial de processamento de dados, que é necessário realizar um número elevado de iterações para avaliar o problema e buscar novos resultados. Isso se faz necessário para possibilitar ao algoritmo explorar com eficiência toda a região do espaço de busca em que está contida a solução ótima, conseqüentemente resultando em grande número de avaliações da função.

Uma das técnicas pertencente à categoria de algoritmos evolucionários e que vem tendo uma boa aceitação é o Algoritmo de Evolução Diferencial (DE) que foi desenvolvido por (STORN; PRICE, 1995). De acordo com (DAS; SUGANTHAN, 2011) as variações do algoritmo diferencial conquistaram a posição de primeiro lugar em 2006 e 2009, segundo lugar em 2007 e terceiro em 2009, sendo assim, demonstra ser um excelente algoritmo de otimização entre os demais, como citado também por (GONG et al., 2009).

Outra técnica recentemente lançada e que tem obtido bons resultados é o algoritmo de otimização de lobos cinzentos, que é uma técnica que mimetiza a hierarquia social e o comportamento de caça dos lobos cinzentos. Para simulação de hierarquia de liderança no algoritmo de Lobos cinzentos, quatro grupos são definidos: alpha, beta, delta, e omega (MIRJALILI et al., 2014).

Neste trabalho, o problema a ser estudado é a estimação dos parâmetros de um regulador de velocidade (controlador PID mais o amplificador hidráulico) de uma Usina Hidrelétrica (UHE) pertencente ao Sistema Nacional Interconectado (SIN). O modelo corresponde a um sistema não linear, o que torna o problema de otimização mais desafiador. A função objetivo corresponde em minimizar o erro entre a resposta do modelo com

dados obtidos em campo. Para a estimação dos parâmetros, serão utilizados dois algoritmos de otimização: o algoritmo de Evolução Diferencial (DE) proposto por (STORN; PRICE, 1995) (DAS; SUGANTHAN, 2011) e algoritmo de otimização dos Lobos Cinzentos (GWO) proposto por (MIRJALILI et al., 2014) (SAREMI et al., 2015).

1.1 Trabalhos relacionados

Em (EL-FERGANY; HASANIEN, 2015) apresenta-se um trabalho dedicado a estimação de parâmetros de um controlador de fluxo de potência, inicialmente sendo mono objetiva e depois seguindo para multi objetiva, aplicando o algoritmo de otimizador de lobos cinzentos (GWO) e evolução diferencial (DE). O problema de estimação corresponde ao fluxo de potência ótimo, com variáveis de restrição no sistema, usado para determinar os valores ótimos das variáveis de controle contínuo e discreto. O objetivo é minimizar quatro funções objetivas, custo do combustível, perdas reais da rede, perdas de potência reativa na rede e o índice de segurança da tensão.

No trabalho (TIJANI et al., 2015), é apresentada a estimação de parâmetros para a sintetização de um controlador H-infinito, para a estimação de parâmetros foi usado a evolução diferencial multi objetiva (MODE), com o intuito de controlar um helicóptero autônomo. De acordo com o autor, o controlador otimizado proposto foi capaz de produzir conjuntos de candidatos do controlador do Pareto com uma confiabilidade ideal entre a estabilidade conflitante e o desempenho do domínio do tempo, que são exigidos para a implementação de helicóptero autônomos.

De acordo com (CHEN et al., 2015), o sistema de regulação de turbina hidráulica é um dos componentes mais importantes de uma planta hidrelétrica para manter a segurança, estabilidade e operação econômica das instalações hidroelétrica, há controladores PID que necessitam ser ajustados com precisão para obter um desempenho satisfatório. Para os ajustes do PID é analisado várias entradas e saídas, sendo assim um problema multiobjetivo. É aplicado o algoritmo multiobjetivo de otimização de exame de partículas de grade adaptativa (AGPSO) para obter ganhos que em seguida são comparados com o algoritmo genético de classificação não dominado II (NSGAI) e o algoritmo evolutivo

pareto de força II (SPEAII), que também são aplicados às condições com carga e sem carga do sistema.

De acordo com o trabalho de (REYNOSO-MEZA et al., 2014), os problemas de controle em engenharia são geralmente multi objetivos, ou seja, há vários requisitos e limitações dentro do problema que necessitam ser cumpridos. O método convencional usado para calcular uma solução de um desejado *trade-off*, é definir uma declaração de otimização. A aplicação das técnicas de otimização multi objetiva analisam o problema e buscam conjuntos de soluções em potencial, possibilitando que o projetista possa analisar o *trade-off* entre eles e escolher qual é o melhor de acordo com suas preferências.

No trabalho de (CHEN et al., 2014), a estimação de parâmetros de um sistema de regulador de velocidade da turbina hidráulica é estudado. O problema de estimação corresponde a sete parâmetros, o seu foco é a estimação com três algoritmos, o algoritmo de busca gravitacional melhorado (IGSA), algoritmo de pesquisa gravitacional padrão (GSA) e algoritmo de otimização de exame de partícula (PSO), realizando a avaliação entre os algoritmos e seus resultados. De acordo com as simulações o algoritmo IGSA demonstrou melhores resultados mediante comparação com os demais algoritmos dessa pesquisa.

1.2 Motivação e Justificativa

A obtenção de modelos eficientes ainda é um desafio quando se deseja representar um sistema levando em conta todas as suas características não lineares. A modelagem caixa cinza é uma técnica que tem se desenvolvido nos últimos anos. Nessa técnica tem-se que algumas informações sobre o sistema são conhecidas e outras devem ser investigadas, aqui procura-se modelar a malha do regulador de velocidade cuja estrutura é conhecida, porém os parâmetros ainda não são completamente conhecidos. Esse método corresponde a estimação de parâmetros e pode-se inferir que a também corresponde a um caso de otimização, pois ao estimar os parâmetros esses são usados para simular o comportamento do sistema e esta resposta é então comparada com a saída real do sistema, os parâmetros que produzem o menor erro são os escolhidos. Atualmente existem uma gama de algo-

ritmos de otimização denominados metaheurística, os quais tem sido empregado em uma gama de problemas nas diversas áreas da ciência. Dessa forma uma alternativa atraente para a estimação de parâmetros é a utilização dessas metaheurísticas como o objetivo de minimizar o erro entre os valores obtidos em simulação com os valores reais do sistema.

1.3 Objetivo Geral

Estimar parâmetros das malhas que compõem o sistema de controle de velocidade de uma Usina hidrelétrica (UHE) pertencente ao sistema nacional interligado (SIN) utilizando os algoritmos de otimização de Lobos Cinzentos (GWO) e algoritmo de Evolução Diferencial (DE) de forma mono objetivo e multiobjetivo.

1.3.1 Objetivos específicos

Os objetivos específicos deste trabalho são:

- Definir as variáveis do sistema de controle de velocidade da UHE a serem otimizadas e suas funções objetivas;
- Implementar os algoritmos DE multiobjetivo e mono objetivo;
- Implementar os algoritmos GWO multiobjetivo e mono objetivo;
- Testar os algoritmos implementados em funções conhecidas e que normalmente são usadas em benchmark;
- Estimar parâmetros utilizando as metaheurísticas DE e GWO;
- Comparar os resultados dos algoritmos com dados obtidos em campo;
- Comparar desempenho entre os algoritmos.

1.4 Estrutura da Dissertação

Essa dissertação está estruturada em cinco capítulos, sendo que, no capítulo 2 é apresentado o sistema de controle de velocidade da usina hidrelétrica juntamente com a sua

formulação matemática. No capítulo 3 são apresentados as metaheurísticas utilizadas nesse trabalho em sua forma mono objetiva e multi objetiva. No capítulo 4 são apresentados resultados obtidos com as metaheurísticas utilizadas e estes são comparados com dados reais obtidos em campo. Finalmente são apresentadas as conclusões e sugestões de trabalhos futuros.

2 SISTEMA DE CONTROLE DE VELOCIDADE DE UMA USINA HIDRELÉTRICA (UHE)

Para que o sistema de geração hidrelétrica possa satisfazer as solicitações de forma a garantir os critérios impostos pelo Operador Nacional do Sistema Elétrico (ONS) é necessário que haja um sistema de controle.

Dentre os possíveis sistemas de controle em uma usina hidrelétrica (UHE), neste trabalho o foco será o Regulador de Velocidade (RV), que tem o objetivo de controlar a velocidade de rotação da turbina, impactando na frequência da tensão terminal do gerador síncrono. A frequência adotada no Brasil é de 60 Hz, sendo assim, o sistema necessita manter essa frequência no valor de operação e para fins de eficiência, o recomendado é que a potência gerada pelo conjunto da turbina/gerador deva ser igual à consumida pela carga (Kundur P, 2010).

A função do regulador de velocidade de acordo com (KHODABAKHSHIAN; HOOSHMAND, 2010) é monitorar a velocidade da turbina e controlar a posição do distribuidor em resposta aos possíveis distúrbios.

Na Figura 2.1 encontram-se os principais componentes de um sistema de geração hidrelétrica.

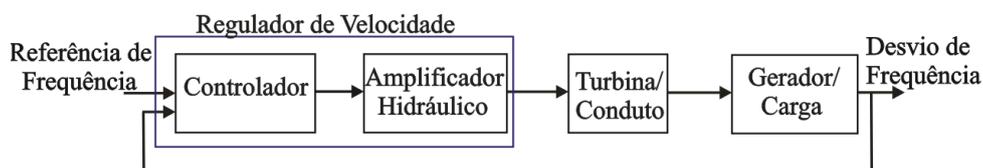


Figura 2.1: Sistema de geração hidrelétrica.

Fonte: (MUNOZ-HERNANDEZ et al., 2013) Adaptado.

Neste capítulo será apresentado o modelo de sistema de controle de velocidade de uma usina hidrelétrica, através de diagrama de blocos e equações integro diferenciais.

Os modelos matemáticos dos componentes do sistema de controle de velocidade que serão apresentados são baseados nos componentes reais de uma Usina Hidrelétrica pertencente à Companhia Energética de Minas Gerais (CEMIG) localizada no sudeste brasileiro, estado de Minas Gerais.

2.1 Modelo matemático do regulador de velocidade

A seguir são apresentadas, em maiores detalhes, as malhas dos componentes que fazem parte do escopo deste trabalho.

2.1.1 Controlador

O controlador tem como objetivo fornecer o sinal de controle adequado para manter a frequência estável e dentro dos valores esperados. Na maioria das UHE e neste estudo, é utilizado o controlador PID para o controle de velocidade, sendo ele apresentado na Figura 2.2.

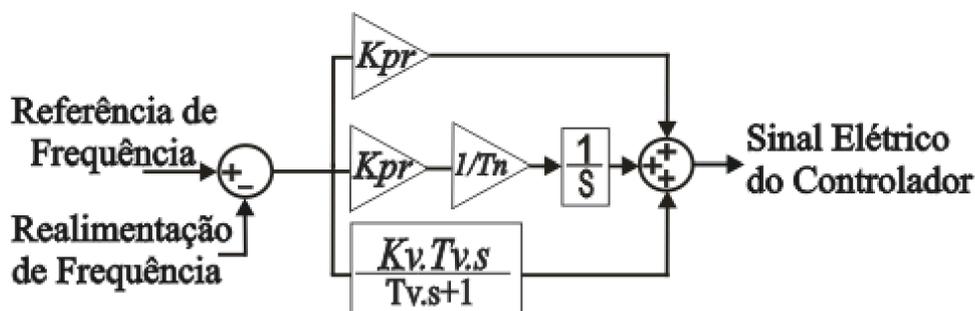


Figura 2.2: Controlador atual da usina.

Fonte: (OSINSKI, 2017).

onde,

K_{pr} = ganho proporcional,

T_n = constante de tempo do integrador,

K_v = ganho do derivador,

T_v = constante de tempo do derivador.

De acordo com (OSINSKI, 2017) o controlador PID tem uma vasta aplicabilidade e vantagem por ser simples e de fácil implementação, sendo muito usado em indústrias, mas seu desempenho pode ser prejudicado caso haja alterações no ponto de operação da planta. Com a variação da demanda de carga, o controlador analisa e detecta as diferenças de frequência e aplica sinais de controle que atuam como sinais de referência para o sistema de controle de posição do servomotor principal.

2.1.2 Amplificador Hidráulico

O sinal de saída do controlador, é repassado para a entrada do sistema de amplificação hidráulica, que tem a função de executar os movimentos dos componentes da turbina para diferentes pontos de operação do sistema, mas para possibilitar isso, se faz necessário diversos estágios hidráulicos, elétricos e eletrônicos, incluindo a válvula piloto, conjunto microprocessado, válvula distribuidora e o distribuidor (Energy Development & Power Generation Committee, 2011) que são ilustrados na Figura 2.3.

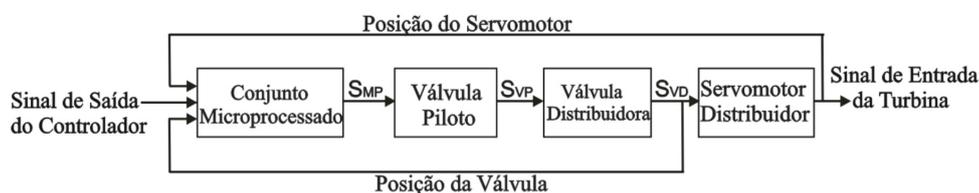


Figura 2.3: Amplificador hidráulico.

Fonte: (OSINSKI, 2017) e (Energy Development & Power Generation Committee, 2011).

Expandindo o bloco do conjunto microprocessado, têm-se na entrada os sinais realimentados da posição do distribuidor (G), da posição da válvula distribuidora (S_{VD}) e o sinal de controle, que podem ver na Figura 2.4. De acordo com (OSINSKI, 2017) a função do bloco de saturação é limitar a saída, em seguida, o segurador de ordem zero tem a função de reconstrução analógica e o ganho dez tem o objetivo de normalizar a variável, para as etapas seguintes. Os ganhos $K1$ e $K2$ estão relacionados com a malha do distribuidor e com a malha da válvula distribuidora respectivamente.

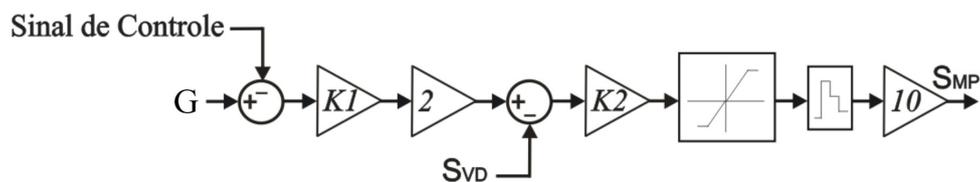


Figura 2.4: Conjunto microprocessado.

Fonte: (OSINSKI, 2017).

onde,

G = saída do distribuidor,

$K1$ = ganho da malha do distribuidor,

$K2$ = ganho da malha distribuidora,

S_{VD} = saída da válvula distribuidora,

S_{MP} = saída do conjunto microprocessado.

A saída do conjunto microprocessado (S_{MP}) é o sinal de entrada da válvula piloto, a qual transforma os sinais elétricos em um deslocamento mecânico hidráulico proporcional, sendo que o seu diagrama de blocos pode ser visto na Figura 2.5. A válvula piloto, é constituída pelo ganho $K3$, responsável pelo ajuste da dinâmica da válvula, os demais blocos em seguida representam a histerese da válvula e a saturação.

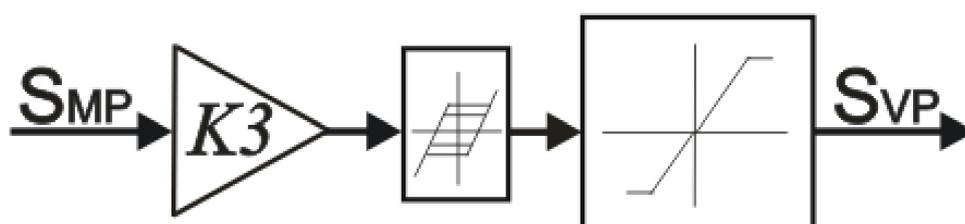


Figura 2.5: Válvula piloto.

Fonte: (OSINSKI, 2017).

onde,

$K3$ = ganho da válvula proporcional.

A saída da válvula piloto (S_{VP}) é o sinal de entrada da válvula distribuidora, cuja estrutura é projetada como uma configuração em série composta por ganhos variáveis e um bloco integrador com não linearidade do tipo saturação, ilustrado na Figura 2.6.

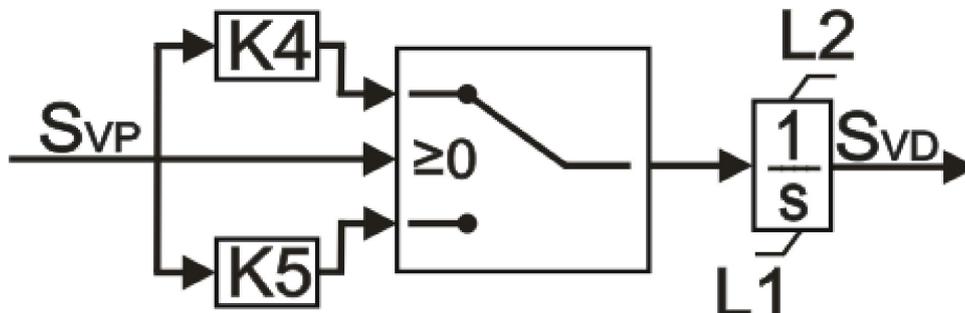


Figura 2.6: Válvula distribuidora.

Fonte: (OSINSKI, 2017).

onde,

$K4$ = ganho da válvula distribuidora no sentido de abertura,

$K5$ = ganho da válvula distribuidora no sentido de fechamento,

$L1$ = limite inferior do integrador,

$L2$ = limite superior do integrador.

A saída da válvula distribuidora (S_{VD}) é o sinal de entrada do distribuidor, cuja estrutura possui dois ganhos que ajustam o sentido de movimentação do deslocamento do distribuidor. Sua estrutura é similar a representação da válvula distribuidora, e sua representação é apresentada na Figura 2.7.

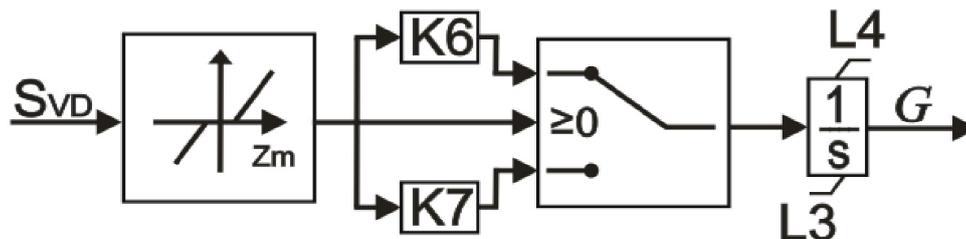


Figura 2.7: Distribuidor.

Fonte: (OSINSKI, 2017).

Onde,

$K6$ = ganho do distribuidor no sentido de abertura,

$K7$ = ganho do distribuidor no sentido de fechamento,

$L3$ = limite inferior do integrador,

$L4$ = limite superior do integrador.

A saída do distribuidor (G) é que irá movimentar as palhetas de admissão de água da turbina regulando a velocidade da mesma.

Nas estruturas apresentadas anteriormente, os sinais de saídas são entradas das estruturas seguintes, correspondendo ao sistema “expandido” do amplificador hidráulico da Figura 2.3. O modelo de (VILLEGAS PICO; MCCALLEY, 2011) foi estudado por (OSINSKI, 2017), que em seu estudo de caso, adicionou nesse modelo uma não linearidade do tipo zona morta.

2.2 Formulação Matemática para a Estimação dos Parâmetros

Na identificação de sistemas, quando se conhece/tem alguma informação do sistema a ser modelado, dá-se a este modelamento o nome de modelagem caixa cinza.

Desta forma, a modelagem caixa cinza parte-se do princípio que se tem alguma informação a priori do sistema, que ajuda a construção do modelo. A partir destas informações é possível prever e simular o comportamento dinâmico do sistema a partir de dados, medições e da estrutura do modelo (LJUNG, 1987) (AGUIRRE et al., 2007).

Segundo (AGUIRRE et al., 2007) e (LJUNG, 2007), a identificação de sistemas pode ser representada pelas seguintes etapas: coleta de dados; estrutura e representação do modelo; estimação de parâmetros; validação do modelo.

A seguir são apresentadas como cada etapa da identificação de sistemas, foi realizada neste trabalho.

2.2.1 Coleta de dados

Os dados foram coletados/medidos simultaneamente por um sistema de aquisição de dados com um período de amostragem de 1 ms, sendo estes dados referentes à saída e entrada do sistema. Porém ao analisar os dados, observa-se que há ruídos neles, com isto, foram submetido a uma filtragem para eliminar os ruídos contidos e assim melhorar a relação sinal ruído dos sinais dos dados de entrada e de saída.

2.2.2 Estrutura e representação do modelo

Outro aspecto importante é a definição da estrutura do modelo. Esse aspecto está relacionado com o tipo de problema se ele é estático ou dinâmico, linear ou não linear, a dimensão do modelo em relação à quantidade de entradas/saídas, a qualidade e quantidade de dados observados, e a complexidade do sistema (AGUIRRE et al., 2007) (LJUNG, 2007).

Para que se possa realizar a estimação dos parâmetros neste trabalho, parte-se da premissa que os modelos matemáticos descritos na seção 2.1, e algumas variáveis/parâmetros são conhecidos (informação a priori do sistema).

2.2.3 Estimação de parâmetros

Após a escolha da estrutura do modelo, o passo seguinte é a estimação de parâmetros. O objetivo da estimação de parâmetros é encontrar valores reais para cada parâmetro ou variável estimada, tentando fazer que a saída do modelo tenha uma quase sobreposição da saída do sistema.

A equação 2.1 representa de forma genérica o processo de estimação de parâmetros utilizando os dados de entrada e saída do sistema.

$$\hat{y} = f(Z(N)) + g(Z(N))\theta \quad (2.1)$$

onde,

$Z(N)$ = a matriz de dados compostas pelas entradas (u) e pelas saídas (y) do modelo,

$N = 1, 2, \dots, n_{amostra}$,

f e g = campos vetoriais $\in \mathbb{R}^N$,

θ = o conjunto de parâmetros a ser estimados através da técnica de otimização. Neste trabalho serão estimados os parâmetros Kpr , Tn , $K1$, $K2$, $K3$, $K4$, $K5$, $K6$, $K7$, que estão presentes nas estruturas do modelos apresentados na seção 2.1.

Segundo (HIBBERT, 1993) algumas considerações que são importantes para avaliar os parâmetros estimados, são: (a) espaço de busca dos parâmetros; (b) os mínimos locais existentes; (c) a continuidade da função objetivo; (d) a precisão ao encontrar os melhores valores para os parâmetros. As relações (c) e (d) estão ligadas a complexidade que as não linearidades traz consigo onde muitos métodos clássicos não conseguem tratar o problema de estimação de parâmetros. As relações (a) e (b) estão relacionadas diretamente aos valores iniciais dos parâmetros.

2.2.4 Validação do modelo

A última etapa é a validação do modelo, onde a qualidade do modelo é analisada e ele pode ser considerado aceito ou rejeitado. Segundo (AGUIRRE et al., 2007) um bom modelo só é validado quando reproduz as características aproximadas ou exatas do sistema identificado.

Os testes dinâmicos validam o modelo com os parâmetros estimados, utilizando os dados obtidos. Nestes testes são realizadas análises visuais comparativas com os dados do sistema identificado, determinando se o modelo está ou não adequado.

Os testes utilizando índices estatísticos fazem geralmente a utilização do erro entre a

saída estimada pelo modelo e a saída real (obtida em campo), dentre eles se tem o MSE (Erro Médio Quadrático) apresentado nas Equações 2.2 e 2.3 , o qual será utilizado neste trabalho.

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (2.2)$$

$$\text{MSE}(\bar{X}) = E[(\bar{X} - \mu)^2] = \frac{\sigma^2}{n} \quad (2.3)$$

onde,

\bar{X} = estimador,

μ = média real,

n = quantidade de amostras,

X_i = amostras,

σ^2 = variância da população das amostras.

3 METAHEURÍSTICAS

Alguns problemas de otimização podem ser definidos como problemas sem soluções por técnicas exatas, ou seja, técnicas determinísticas. As metaheurísticas são uma alternativa para estas situações, não há garantia de que elas irão encontrar a solução ótima global, porém elas propiciarão uma solução factível (BOUSSAÏD et al., 2013).

Em (MIRJALILI, 2015), é descrito os algoritmos metaheurísticos como técnicas primárias para obter soluções ótimas de problemas reais de otimização do cotidiano. Estes algoritmos se beneficiam de operadores estocásticos existentes neles, para explorar o espaço de soluções de forma aleatória propiciando maior oportunidade de encontrar as soluções.

A principal característica das metaheurísticas é a aleatoriedade, pois elas dependem de operadores estocásticos. Esta característica deixa o algoritmo mais propício à obtenção da solução factível a cada execução. Além disto, elas utilizam a formulação do problema para avaliar o conjunto de soluções, o processo é realizado independentemente do problema e com base nas entradas dadas e saídas dadas (COELHO; COELHO, 2004).

Conforme (ARROYO, 2002) a escolha do método de resolução, depende da razão entre a qualidade da solução gerada por tal método e o tempo que ele gasta para encontrar soluções (tempo de processamento utilizado pelo algoritmo).

Atualmente várias metaheurísticas vêm sendo utilizadas para tratar da estimação de parâmetros, tais como: Algoritmo Genético (CHANG, 2007), Evolução Diferencial (FERRARI, 2015), Otimização de Partículas de Enxames (SEVERINO; ARAÚJO, 2015) e Busca Local Iterativa (LOURENÇO et al., 2003) entre outros.

Neste capítulo serão apresentados as metaheurísticas que serão utilizadas no decorrer desse trabalho. Elas serão apresentadas tanto para problemas mono objetivo, como multi objetivo.

A metaheurística evolução diferencial (DE) é baseada na população de indivíduos e sua solução é obtida escolhendo o indivíduo com melhor aptidão baseado na seleção natural.

A metaheurística de otimização de lobos cinzentos é baseada no comportamento de

caça dos lobos cinzentos, sendo que, a solução é obtida quando o algoritmo chega no ataque da presa.

3.1 Evolução Diferencial Mono Objetiva

O algoritmo de Evolução Diferencial (ED) foi desenvolvido por (STORN; PRICE, 1995) para ser confiável, robusto e resolver diversos problemas de otimização. É um algoritmo baseado em população e computação evolucionária, os estágios do algoritmo ED correspondem a inicialização, mutação, cruzamento, seleção e validação da convergência como demonstrado na Figura 3.1.



Figura 3.1: Fluxograma do algoritmo de Evolução Diferencial.

Fonte: (OLIVEIRA et al., 2017).

A seguir é tratado, com alguns detalhes, cada estágio do algoritmo Evolução Diferencial.

3.1.1 Inicialização

O algoritmo DE busca a solução ótima global em um espaço de busca D dimensional, formatado pela dimensão do problema (D). Inicialmente são gerados vetores, com valores aleatórios, de tamanho D , chamados de indivíduos. A geração de vários indivíduos forma a população (NP). Os valores dos indivíduos na população inicial são uniformemente distribuídos com valores aleatórios que variam entre o limite inferior e superior do espaço de busca, cada um desses indivíduos correspondem a soluções candidatas (DAS; SUGANTHAN, 2011), (STORN; PRICE, 1995) e (PRICE, 1996).

Como a cada geração os indivíduos serão alterados, será adotada a seguinte notação,

Equação 3.1, para a representação da população da atual geração.

$$\{X_g = (x_{i,g}) | i = 1, 2, \dots, NP\} \quad (3.1)$$

onde:

NP = tamanho da população,

g = gerações.

Para cada solução candidata do problema, pode haver restrições dentro de um intervalo, chamado de espaço de busca, pois muitas vezes os problemas estão relacionados a equações físicas, químicas, ou medidas naturais que possuem limitações como massa, comprimento, ou seja, não podendo ser negativa. Desta forma, a população inicial deve ser gerada uniformemente entre os valores dos limiares máximo e mínimo, como descrito na Equação 3.2.

$$x_{i,0} = x_{i,low} + rand_{i,j}[0,1] \cdot (x_{i,high} - x_{i,low}) \quad (3.2)$$

sendo que:

$$x_{i,low} \leq x_{i,0} \leq x_{i,high} \quad (3.3)$$

onde:

$x_{i,low}$ = limites inferiores do vetor i ,

$x_{i,high}$ = limites superiores do vetor i ,

$rand_{i,j}(0,1)$ é o número aleatório uniformemente distribuído, entre 0 e 1.

3.1.2 Mutaçãõ

No contexto biológico, a mutação significa uma mudança repentina nas características genéticas de um cromossomo (cromossomo equivale a um individuo da população nesse caso). Mas no contexto genético de algoritmos evolutivos, pode ser visto como a mudança no comportamento aleatório dos algoritmos.

Sendo assim, o grupo dos algoritmos evolutivos em geral, simulam o efeito de mutação com incrementos aditivos que são gerados aleatoriamente por uma função de distribuição de probabilidade predefinida (DPP).

No entanto o algoritmo de evolução diferencial, a cada geração g , gera novos vetores de parâmetros através da adição da diferença ponderada entre dois vetores de parâmetros a um terceiro indivíduo, criando o vetor de mutação $v_{i,g}$. Para realizar a mutação as técnicas frequentemente usadas são (STORN; PRICE, 1995):

DE/best/1:

$$x_{i,g} = x_{best,g} + F(x_{r1,g} - x_{r2,g}) \quad (3.4)$$

DE/rand/1:

$$v_{i,g} = x_{r0,g} + F(x_{r1,g} - x_{r2,g}) \quad (3.5)$$

DE/current-to-rest/1:

$$v_{i,g} = x_{i,g} + F(x_{best,g} - x_{i,g}) + F(x_{r1,g} - x_{r2,g}) \quad (3.6)$$

onde:

$r0, r1, r2$ = valores uniformemente distintos e escolhidos a partir do vetor,

$x_{r1,g} - x_{r2,g}$ = vetor de diferença para mutar o pai,

$x_{best,g}$ = melhor vetor a partir da geração atual,

F = fator de mutação.

Na Figura 3.2 é demonstrado o processo de mutação diferencial utilizando o "DE/rand/1".

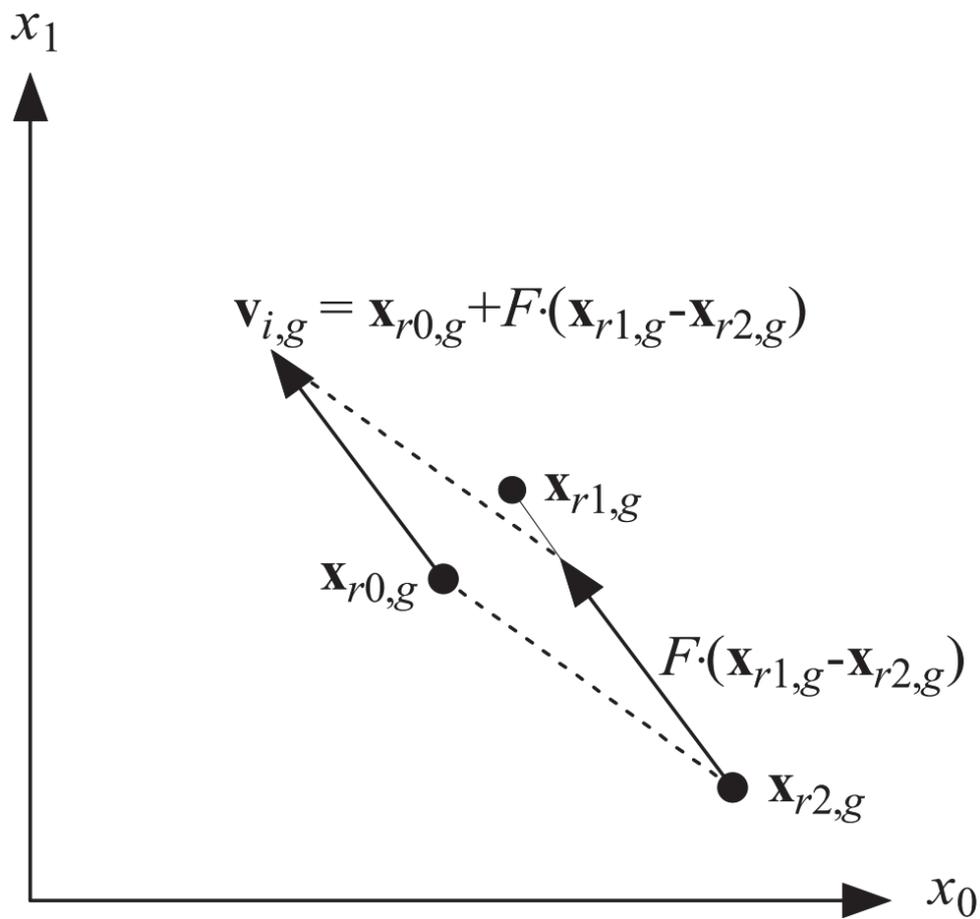


Figura 3.2: Mutaç o Diferencial.

Fonte: (EDITORS et al., 2008).

O fator de mutaç o F corresponde ao n mero real positivo que define o tamanho do passo a ser dado em direç o definida pela diferenç a do vetor $(x_{r1,g} - x_{r2,g})$. De acordo com (EDITORS et al., 2008), mesmo que n o haja um limite m ximo para F , raramente os valores s o maiores que 1 .

3.1.3 Cruzamento

Com o objetivo de aumentar a diversidade potencial da populaç o, complementando a estrat gia de mutaç o diferencial, o processo de cruzamento   realizado ap s a mutaç o.

Para gerar o vetor experimental da equa o 3.7,   executado uma combinaç o binomial, com o objetivo de incrementar a diversidade dos vetor de par metros de mutaç o.

$$u_{i,g} = (u_{1,i}, u_{2,i}, \dots, u_{D,i}) \quad (3.7)$$

Cruza-se cada vetor com um vetor mutante, de acordo com as equações e condições a seguir:

$$u_{j,i} = \begin{cases} u_{j,i} & \text{se } rand(0,1) \leq CR_i \\ x_{j,i} & \text{caso contrario} \end{cases} \quad (3.8)$$

A equação 3.8 corresponde a aproximação média fracionária dos vetores inerentes dentro do processo de mutação.

3.1.4 Seleção

Se o vetor experimental da população $u_{i,g}$, tem o valor da sua função igual ou menor ao valor da função objetiva do vetor alvo $x_{i,g}$, substitui o vetor alvo na próxima geração. Caso contrário, o alvo mantém seu lugar na população no mínimo por mais uma geração conforme a Equação 3.9. Ao comparar cada vetor experimental com o vetor alvo a partir do qual herda os parâmetros, resulta em uma integração mais forte a recombinação e a seleção.

$$x_{i,g+1} = \begin{cases} u_{i,g} & \text{se } f(u_{i,g}) \leq f(x_{i,g}) \\ x_{i,g} & \text{caso contrário} \end{cases} \quad (3.9)$$

3.1.5 Convergência

O processo converge quando chega ao número máximo de iterações ou quando chega ao objetivo desejado. Sendo assim, o processo conclui, senão, continua executando as demais iterações.

3.2 Evolução Diferencial Multi Objetiva

No mundo real, geralmente os problemas de otimização envolvem múltiplos objetivos.

O foco da solução do problema é:

$$\text{Minimizar } f(x) := [f_1(x), f_2(x), \dots, f_k(x)] \quad (3.10)$$

Sujeito a:

$$g_i(x) \leq 0 \quad i = 1, 2, \dots, m \quad (3.11)$$

$$h_i(x) = 0 \quad i = 1, 2, \dots, p \quad (3.12)$$

sendo que:

$x = [x_1, x_2, \dots, x_n]^T$ = vetor de variáveis de decisão;

$f_i : \mathbb{R}^n \rightarrow \mathbb{R}, i = 1, \dots, k$ = funções objetivas;

$g_i, h_j : \mathbb{R}^n \rightarrow \mathbb{R}, i = 1, \dots, m, j = 1, \dots, p$ = funções de restrição do problema.

De acordo com (MEZURA-MONTES et al., 2008), as variantes bases do algoritmo de evolução diferencial multiobjetivo são:

rand/p/bin:

$$u_{i,j} = \begin{cases} x_{r3,j} + F \cdot \sum_{k=1}^p (x_{r1,j} - x_{r2,j}) & \text{se } rand(0,1) < CR \text{ ou } j = j_r \\ x_{i,j} & \text{caso contrário} \end{cases} \quad (3.13)$$

rand/p/exp:

$$u_{i,j} = \begin{cases} x_{r3,j} + F \cdot \sum_{k=1}^p (x_{r1,j} - x_{r2,j}) & \text{desde que } rand(0,1) < CR \text{ ou } j = j_r \\ x_{i,j} & \text{caso contrário} \end{cases} \quad (3.14)$$

best/p/bin:

$$u_{i,j} = \begin{cases} x_{best,j} + F \cdot \sum_{k=1}^p (x_{r1,j} - x_{r2,j}) & \text{se } rand(0,1) < CR \text{ ou } j = j_r \\ x_{i,j} & \text{caso contrário} \end{cases} \quad (3.15)$$

best/p/exp:

$$u_{i,j} = \begin{cases} x_{best,j} + F \cdot \sum_{k=1}^p (x_{r_1,j} - x_{r_2,j}) & \text{desde que } rand(0,1) < CR \text{ ou } j = j_r \\ x_{i,j} & \text{caso contrário} \end{cases} \quad (3.16)$$

current-to-rand/p:

$$u_i = x_i + K \cdot (x_{r_3} - x_i) + F \cdot \sum_{k=1}^p (x_{r_1} - x_{r_2}) \quad (3.17)$$

current-to-best/p:

$$u_i = x_i + K \cdot (x_{best} - x_i) + F \cdot \sum_{k=1}^p (x_{r_1} - x_{r_2}) \quad (3.18)$$

current-to-rand/p/bin:

$$u_{i,j} = \begin{cases} x_{i,j} + K \cdot (x_{(r_3),j} - x_{i,j}) + F \cdot \sum_{k=1}^p (x_{r_1,j} - x_{r_2,j}) & \text{se } randj(0,1) < CR \text{ ou } j = j_r \\ x_{i,j} & \text{caso contrário} \end{cases} \quad (3.19)$$

onde:

j = número aleatório inteiro gerado entre $[0,n]$;

n = número de variáveis;

p = número par das soluções usadas para calcular as diferenças entre o operador de mutação;

u_i = vetor filho/experimental;

x_r = soluções de doadores escolhida de forma aleatória;

x_{best} = melhor solução da população como solução de doador;

x_i = vetor pai/antigo;

x_{r_1} e x_{r_2} = são os pares para calcular a mutação diferencial.

Os valores aleatórios são gerados a partir de uma distribuição uniforme.

3.3 Otimizador Lobos Cinzentos Mono Objetivo

O algoritmo Otimizador Lobos Cinzentos (GWO) é inspirado no comportamento dos Lobos Cinzentos (*Canis Lupus*) em seu real *habitat* (MIRJALILI et al., 2014) (SAREMI et al., 2015), há as etapas de hierarquia de liderança, caçar, buscar, cercar e atacar a presa. Na simulação do modelo, a hierarquia de liderança é dividida em quatro tipos de lobos, o alpha α , beta β , delta δ e omega ω . Seu modelo de simulação é definido pelas etapas de caça e busca, cercamento e ataque da presa. O processo do GWO é apresentado na Figura 3.3.

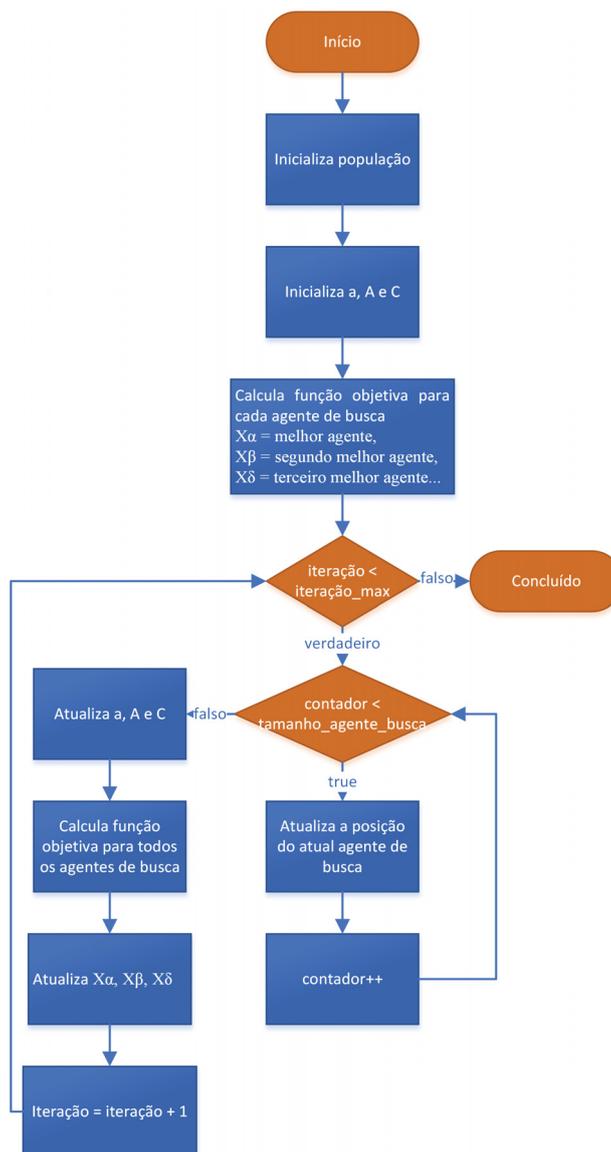


Figura 3.3: Fluxograma Otimizador Lobos Cinzentos.

Fonte: (OLIVEIRA et al., 2017).

3.3.1 Hierarquia de Liderança

A hierarquia dos lobos é dividida em quatro níveis, chamados alpha α (maior nível), beta β , delta δ e omega ω (menor nível) de acordo com a Figura 3.4. O primeiro nível inicia armazenando a melhor solução em alpha e decrementando a posição em sequência.

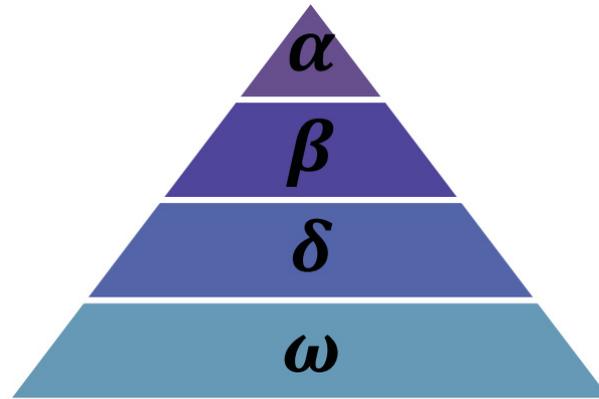


Figura 3.4: Hierarquia de liderança.

Fonte: (MIRJALILI et al., 2014).

3.3.2 Cercar a presa

De acordo com (MIRJALILI et al., 2014), os lobos cinzentos cercam a presa durante a caça, para representar matematicamente a situação de cercar a presa são utilizadas as equações a seguir:

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (3.20)$$

onde:

\vec{A} e \vec{C} = vetores de coeficientes, que é multiplicado elemento por elemento;

t = iteração atual;

\vec{X}_p = vetor de posição da presa;

\vec{X} = vetor de posição do lobo cinzento.

Para calcular \vec{A} e \vec{C} são utilizadas as seguintes equações:

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 \quad (3.21)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (3.22)$$

onde:

\vec{a} = linearmente decrementado de 2 a 0 ao decorrer das iterações, com passo de 0.1,

r_1, r_2 = vetores com valores aleatórios entre 0 e 1.

3.3.3 Caçar

Na caça, o comportamento dos lobos cinzentos é de procurar e cercar a presa, que é guiado pelo lobo alpha, sendo que beta e delta podem participar ocasionalmente (MIR-JALILI et al., 2014). Mas devido ao espaço de busca ser abstrato, não há uma ideia concentrada de qual é a localização do valor ótimo (presa). Sendo assim, é simulado matematicamente o comportamento de caça, supondo que o alpha é a melhor solução candidata e o beta e delta são a segunda e terceira melhor solução. Mediante isso, são salvos os três melhores valores e a cada iteração atualizam-se os melhores agentes e suas respectivas soluções. A caça é representada pelas equações a seguir:

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad (3.23)$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \quad (3.24)$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (3.25)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha) \quad (3.26)$$

$$\vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta) \quad (3.27)$$

$$\vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \quad (3.28)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (3.29)$$

3.3.4 Atacar presa

O termino do processo de caça acontece quando a presa é parada, sendo representado matematicamente quando os valores \vec{a} e \vec{A} são minimizados. O comportamento de alcance de \vec{A} é também decrementado por \vec{a} .

3.3.5 Buscar presa

A posição geográfica diverge para cada lobo cinzento para buscar a presa ou convergir para o ataque. O processo de busca pode ser representado matematicamente, atribuindo a cada lobo níveis hierárquicos aleatórios, os quais são maiores que 1 ou menores do que -1. Esses valores forçam o agente de busca a divergir da presa, resultando em um melhor comportamento para a busca global (MIRJALILI et al., 2014).

Quando $\vec{A} > 1$ força a presa divergir e $\vec{A} < 1$ força a presa convergir, como demonstrado na Figura 3.5, o \vec{C} correspondem a valores aleatórios entre 0 e 2.

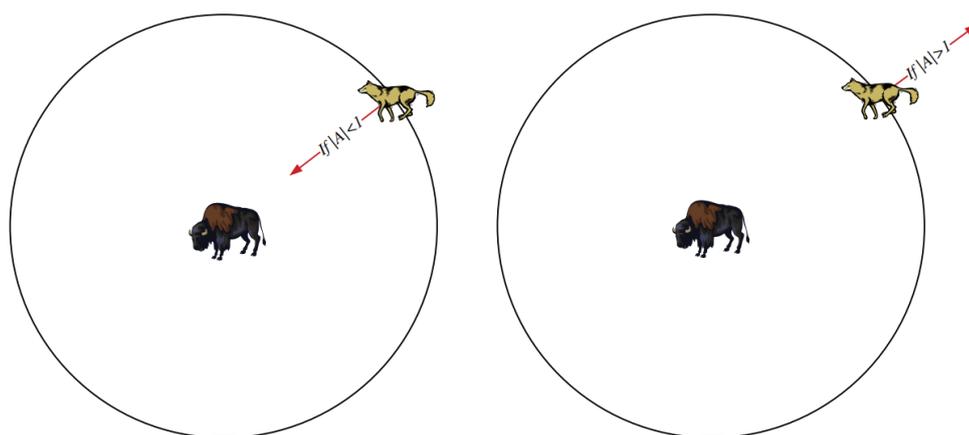


Figura 3.5: Seleção de ataque ou busca da presa.

Fonte: (MIRJALILI et al., 2014).

3.4 Otimizador Lobos Cinzentos Multiobjetivo

O algoritmo de otimização Lobos Cinzentos Multiobjetivo tem o funcionamento similar ao mono objetivo, mas com modificações para trabalhar com duas ou mais funções objetivas, seu funcionamento é demonstrado na Figura 3.6.

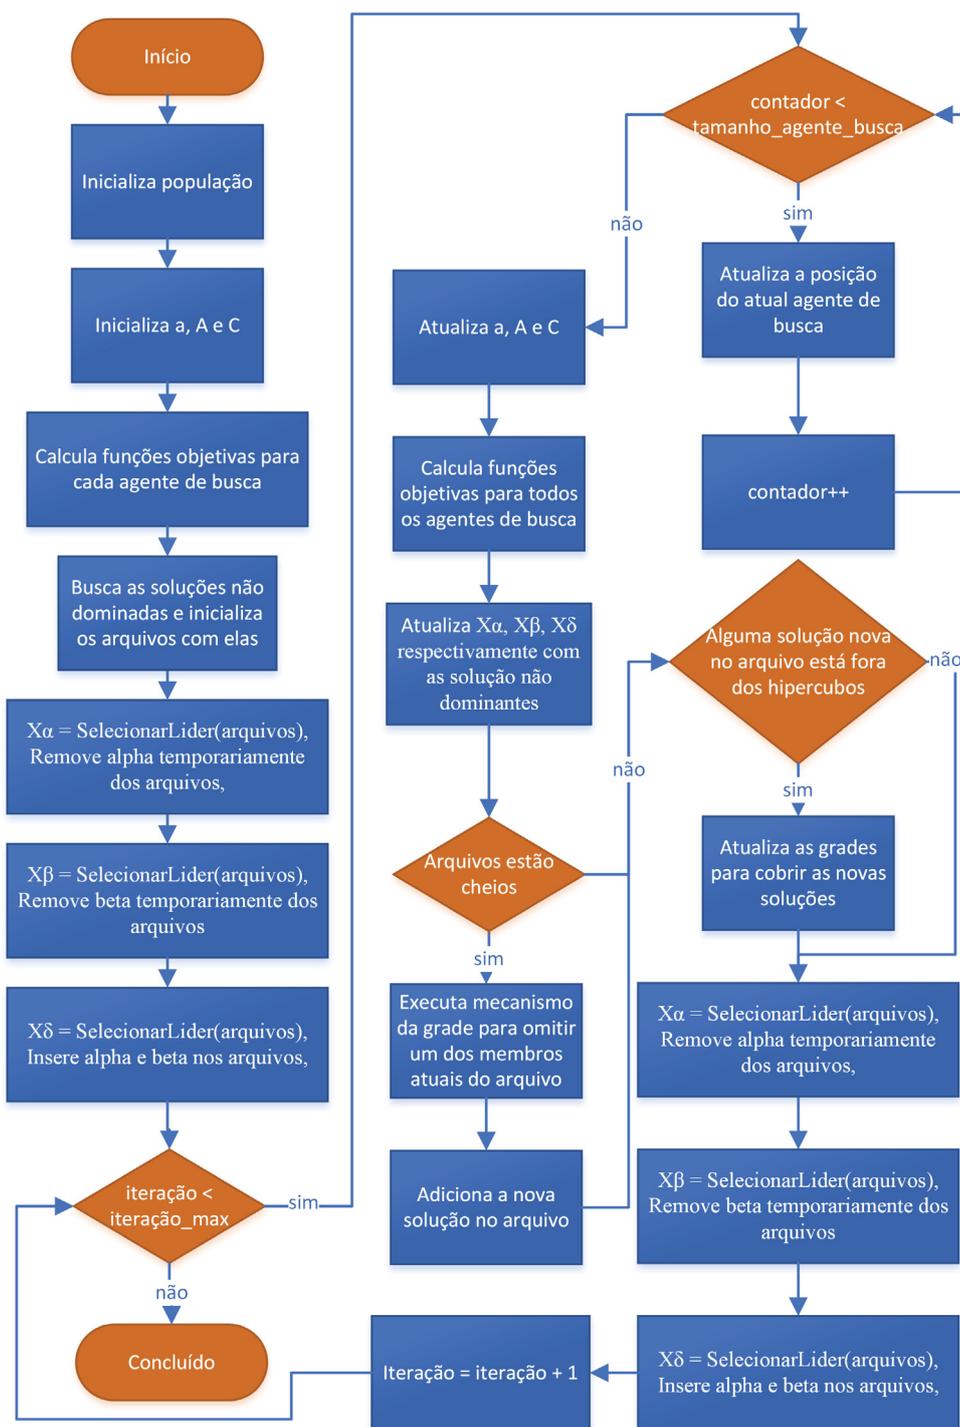


Figura 3.6: Fluxograma do Lobos Cinzentos Multiobjetivo.

Fonte: (OLIVEIRA et al., 2017).

Na Figura 3.6 é apresentada as mesmas funções que tem no algoritmo de Lobos Cinzentos mono objetivo, mas com incrementos para realizar o processo multi objetivos.

4 RESULTADOS

Neste capítulo são apresentados os resultados obtidos com os algoritmos de Evolução Diferencial e Lobos Cinzentos para três estudos de caso, sendo eles: função teste de Ackley, Griewank e Spheref; estimação de parâmetros do regulador de velocidade (controlador PID mais malha hidráulica) de uma usina hidrelétrica cujos dados de campo foram obtidos em loco, e a usina hidroelétrica pertencente ao Sistema Interligado Nacional (SIN), localizada na região sudeste do Brasil.

As funções de testes foram utilizadas para uma avaliação das metaheurísticas, e para a validação do desempenho de cada algoritmo. Com isto, verificou-se se as mesmas obtinham resultados semelhantes aos relatados na literatura.

Para a obtenção dos resultados simulados do regulador de velocidade foram utilizados os softwares Matlab e ANATEM¹. Sendo que, no Matlab era rodado os algoritmos de otimização (DE, GWO) que geram as potenciais soluções, e no ANATEM era simulado o regulador de velocidade da usina hidrelétrica (UHE), estando ela conectada ao Sistema Interligado Nacional (SIN).

¹Software ANATEM - Análise de Transitórios Eletromecânicos. Usado para análise de Sistemas Elétricos de Potência em regime dinâmico. Destina-se à análise de grandes perturbações nos sistemas de potência, compreendendo os períodos de estabilidade transitória e dinâmica.

4.1 Funções de avaliação - Benchmark

Para fins de validação dos algoritmos de otimização na forma mono objetivo, foram utilizados algumas funções padrões de Benchmark, contendo vários mínimos locais e um mínimo global.

4.1.1 Função de Benchmark Ackley

A função Ackley (ADORIO; DILIMAN, 2005) (MOLGA; SMUTNICKI, 2005) é amplamente usada para testar algoritmos de otimização. Em sua forma bidimensional, como mostrado na Figura 4.1, é caracterizado por uma região externa quase plana e um grande buraco no centro. A função representa um risco para os algoritmos de otimização de ficarem presos em um de seus muitos mínimos locais.

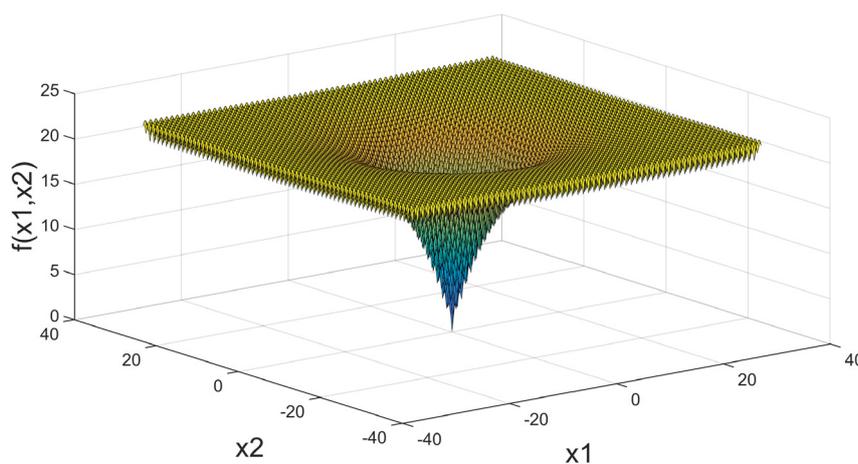


Figura 4.1: Gráfico da função de Ackley de $n = 2$

Fonte: (OLIVEIRA et al., 2017).

$$\begin{aligned}
f(x_0 \cdots x_n) &= -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e \\
&\quad -32 \leq x_i \leq 32 \\
&\quad \text{mínimo } f(0, \dots, 0) = 0
\end{aligned}
\tag{4.1}$$

A Figura 4.2 mostra o gráfico do MSE dos algoritmos de evolução diferencial e lobos cinzentos, quando estes são executados 100 vezes, tendo cada uma das execuções 100 iterações, sendo D a dimensão do problema, que é igual a 50.

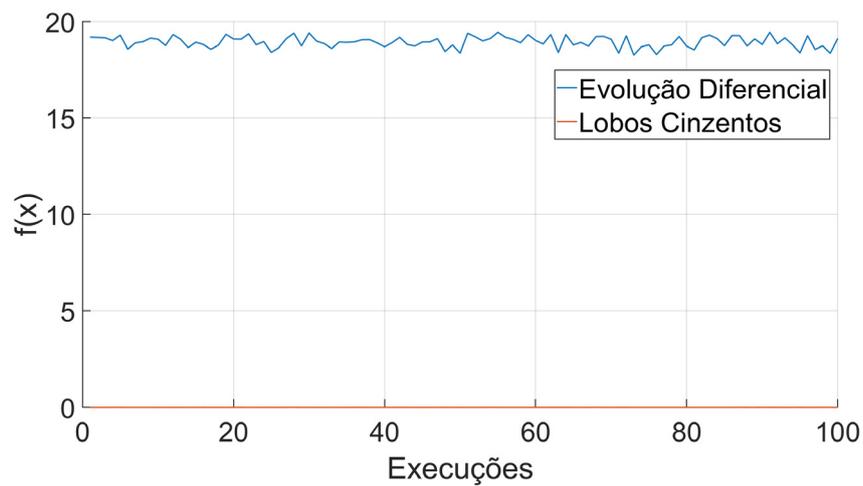


Figura 4.2: MSE dos algoritmos DE e GW para função de Ackley, dimensão = 50

Fonte: (OLIVEIRA et al., 2017).

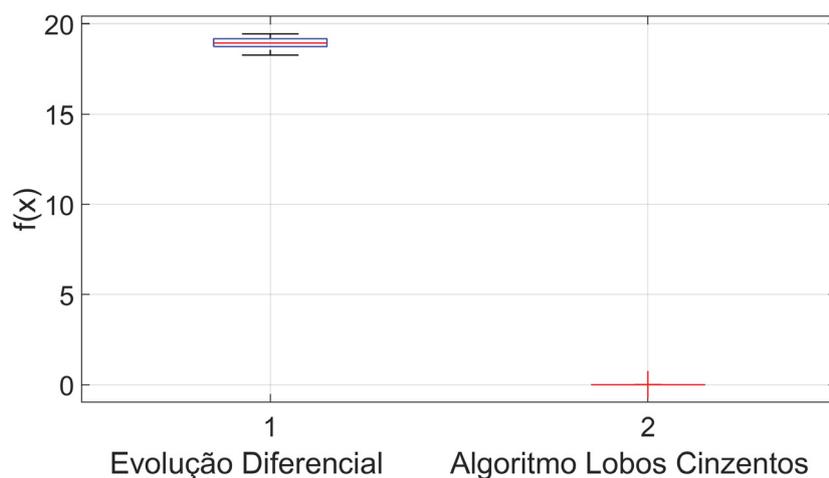


Figura 4.3: MSE dos algoritmos DE e GWO para a função de Ackley, dimensão = 50

Observando as Figuras 4.2 e 4.3, vê-se que o algoritmo dos lobos cinzentos possui um melhor desempenho do que o algoritmo de evolução diferencial, pois nas 100 execuções ele alcança a solução ótima, enquanto a DE tem seu valor médio em torno 18.

Para uma mostra mais evidente da convergência dos dois algoritmos, as Figuras 4.4 e 4.5 mostrando os resultados para um mesmo problema agora este tendo dimensão 500.

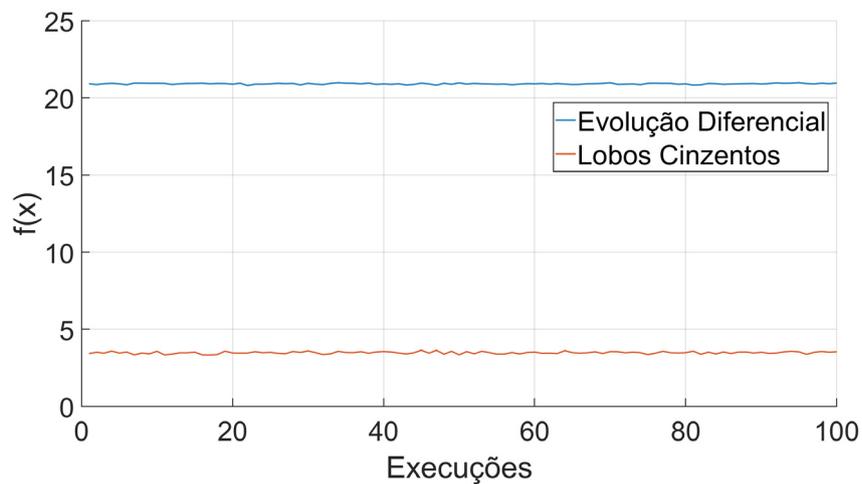


Figura 4.4: MSE dos algoritmos DE e GWO para função de Ackley, dimensão = 500

Fonte: (OLIVEIRA et al., 2017).

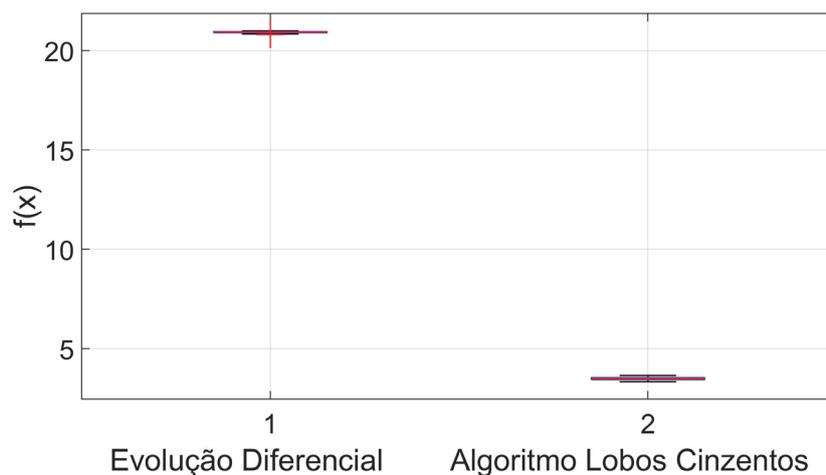


Figura 4.5: MSE dos algoritmos DE e GWO para a função de Ackley, dimensão = 500

Fonte: (OLIVEIRA et al., 2017).

Observando as Figuras 4.2 e 4.3, essas demonstram que neste caso, mesmo que tenham bons resultados, ambos os algoritmos não conseguem convergir ao valor zero, pois leva-se em consideração um espaço de busca maior e mais parâmetros a serem otimizados, sendo assim, quanto maior a dimensão, maior será a complexidade de convergência.

Na Figura 4.6 e 4.7 são apresentadas as iterações de uma execução dos algoritmos DE e GWO.

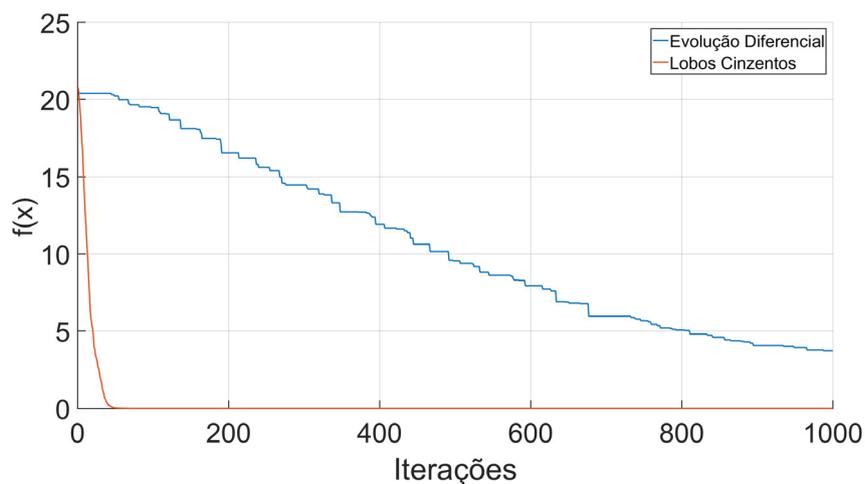


Figura 4.6: MSE dos algoritmos DE e GWO para uma execução com iteração = 1000 e dimensão = 50, da função de Ackley

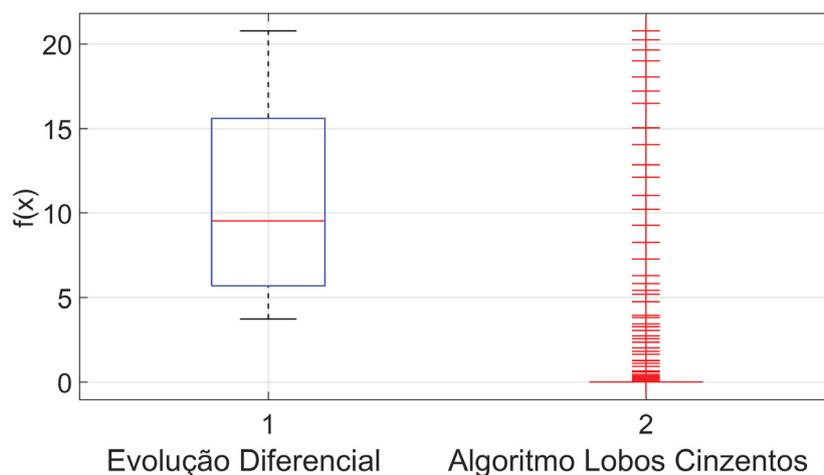


Figura 4.7: MSE dos algoritmos DE e GWO para uma execução com iteração = 1000 e dimensão = 50, da função de Ackley

É demonstrado nas Figuras 4.6 e 4.7 o comportamento da convergência dos algoritmos DE e GWO para uma iteração, observa-se que o algoritmo GWO converge rapidamente para a solução ótima, enquanto que, o DE após 1000 iterações ainda não chegou a solução ótima.

4.1.2 Função de Benchmark Greiwank

A função Griewank (MOLGA; SMUTNICKI, 2005) possui muitos mínimos locais, que são distribuídos regularmente. A sua forma gráfica é mostrada na Figura 4.8.

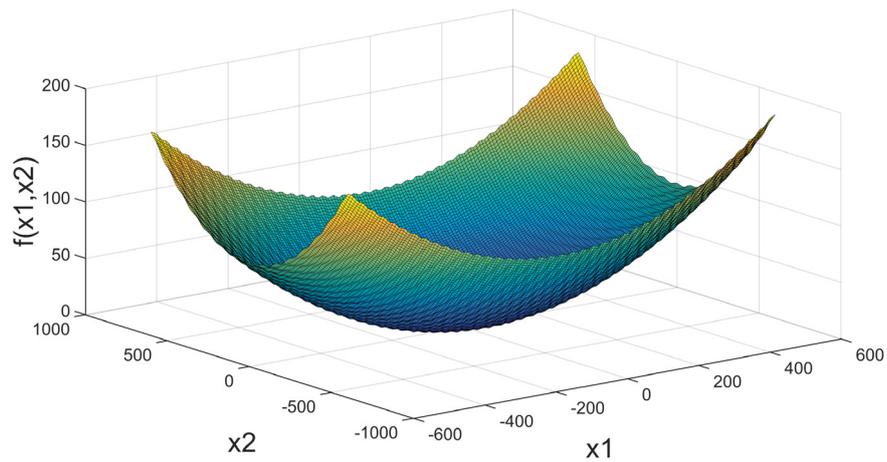


Figura 4.8: Gráfico da função de Griewank de $n = 2$

Fonte: (OLIVEIRA et al., 2017).

$$f(x_1 \cdots x_n) = 1 + \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right)$$

$$- 512 \leq x_i \leq 512$$

$$\text{mínimo } f(0, \cdots, 0) = 0$$

(4.2)

A Figura 4.9 mostra o gráfico do MSE dos algoritmos de evolução diferencial e lobos cinzentos, quando estes são executados 100 vezes, tendo cada uma das execuções 100 iterações, sendo a dimensão (D) do problema igual a 50.

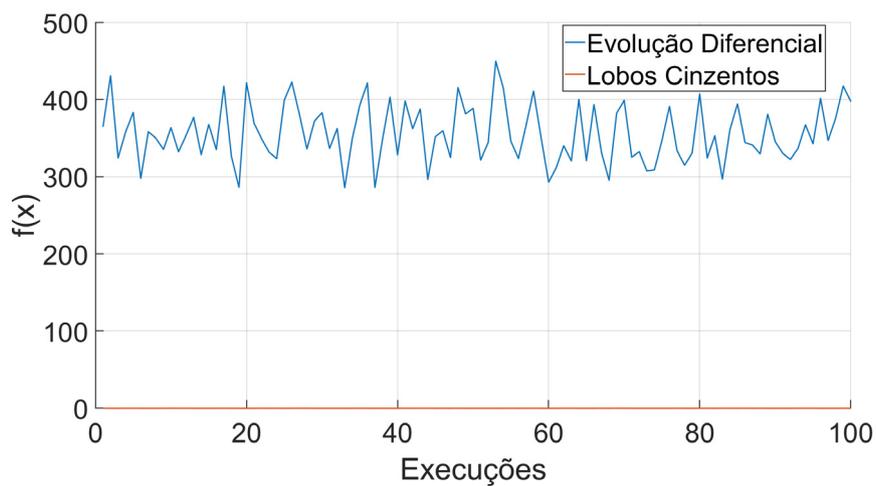


Figura 4.9: MSE dos algoritmos DE e GWO para função de Griewank, dimensão = 50

Fonte: (OLIVEIRA et al., 2017).

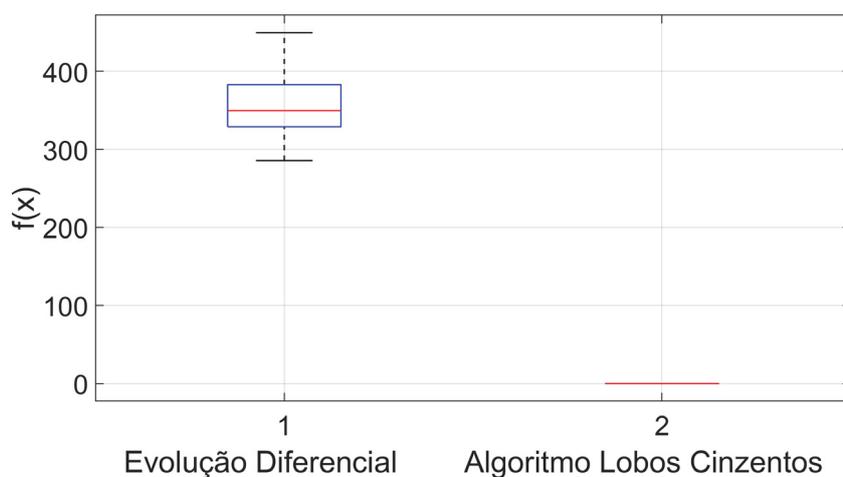


Figura 4.10: MSE dos algoritmos DE e GWO para a função de Griewank, dimensão = 50

Fonte: (OLIVEIRA et al., 2017).

Observando as Figuras 4.9 e 4.10, vê-se que o algoritmo dos lobos cinzentos possui um melhor desempenho do que o algoritmo de evolução diferencial, pois nas 100 execuções ele alcança a solução ótima, enquanto a DE tem seu valor médio em torno 350.

4.1.3 Função de Benchmark Spheref

A função Spheref (MOLGA; SMUTNICKI, 2005) (DIXON; SZEGÖ, 1975) possui d mínimos locais, exceto o global. Ela é contínua, convexa e unimodal, sendo apresentada na Figura 4.11.

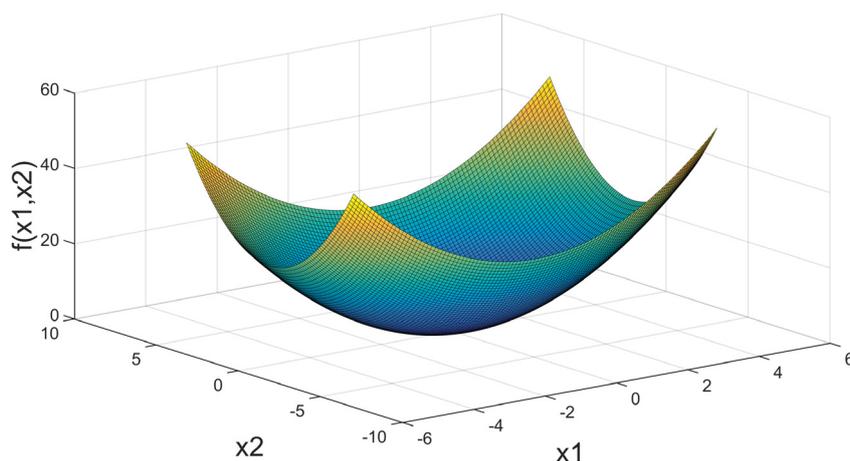


Figura 4.11: Gráfico da função de Spheref de $n = 2$

Fonte: (OLIVEIRA et al., 2017).

$$\begin{aligned}
 f(x) &= \sum_{i=1}^n x_i^2 \\
 -5.12 &\leq x_i \leq 5.12 \\
 \text{mínimo } f(0, \dots, 0) &= 0
 \end{aligned}
 \tag{4.3}$$

A Figura 4.12 mostra o gráfico do MSE dos algoritmos de evolução diferencial e lobos cinzentos, quando estes são executados 100 vezes, tendo cada uma das execuções 100 iterações, sendo a dimensão (D) do problema igual a 50.

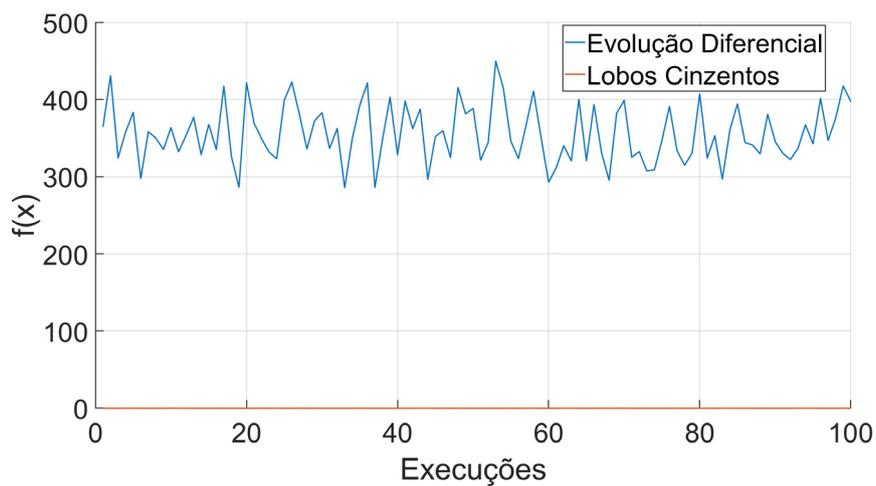


Figura 4.12: MSE dos algoritmos DE e GWO para função de Spherf, dimensão = 50

Fonte: (OLIVEIRA et al., 2017).

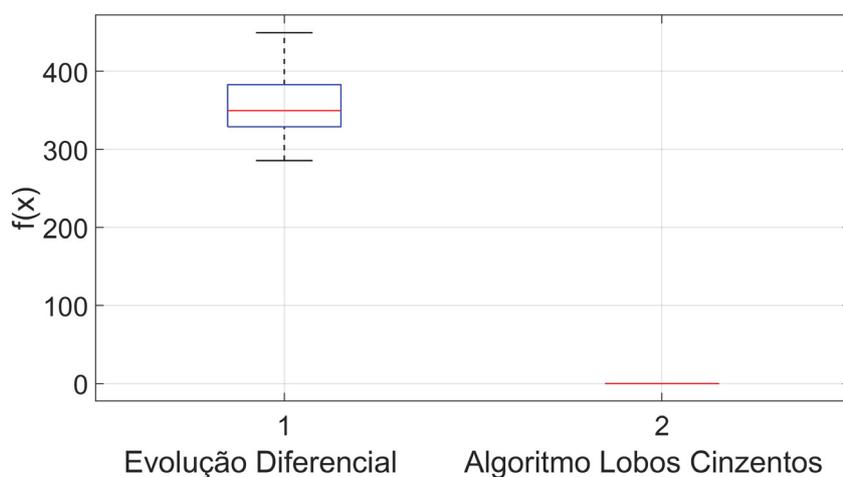


Figura 4.13: MSE dos algoritmos DE e GWO para a função de Spherf, dimensão = 50

Fonte: (OLIVEIRA et al., 2017).

Observando as Figuras 4.12 e 4.13, vê-se que o algoritmo dos lobos cinzentos possui um melhor desempenho do que o algoritmo de evolução diferencial, pois nas 100 execuções ele alcança a solução ótima, enquanto a DE tem seu valor médio em torno 350.

4.2 Resultados com os algoritmos Mono e Multiobjetivo de Evolução diferencial e Lobos cinzentos

Nessa seção são apresentados os resultados para o estudo de caso (rejeição de carga) utilizando o algoritmo de evolução diferencial e lobos cinzentos em modo mono objetivo e multiobjetivo.

Nesse estudo de caso a usina inicialmente está interligada ao SIN, sendo depois desinterligada e tendo que suprir uma carga menor do que havia inicialmente.

Os algoritmos mono objetivos estimam os parâmetros de cada função de forma independente, após estimar os valores da primeira função objetiva e obter bons resultados, é executado em sequência a próxima função objetiva. Mas os algoritmos multi objetivos, otimizam todos os parâmetros e analisam todas as saídas.

Os algoritmos de evolução diferencial mono objetivo e multiobjetivo utilizaram os parâmetros da Tabela 4.1.

Tabela 4.1: Parâmetros do DE e MODE

Tamanho da população	Dimensão · 30
Iteração máxima	600
Probabilidade de cruzamento	0,5
Fator de escala	0,8
Estratégia	DE/best/1/bin

Os algoritmos de otimização de lobos cinzentos mono objetivo e multiobjetivo utilizaram os parâmetros da Tabela 4.2 e Tabela 4.3 respectivamente.

Tabela 4.2: Parâmetros do GWO

Tamanho da população/ Número de agentes de busca	Dimensão · 30
Iteração máxima	600

Tabela 4.3: Parâmetros do MOGWO

Tamanho da população	Dimensão · 30
Iteração máxima	600
Qntd. Grids por dimensão	10
Alpha	0,1
Beta	4
Gama	2

Sendo que a dimensão de cada estrutura de ambos os algoritmos, corresponde aos valores da Tabela 4.4.

Tabela 4.4: Dimensão dos parâmetros de estimação das estruturas

	Dimensão
Válvula distribuidora	2
Tensão do controlador	4
Transdutor da válvula distribuidora	2
Válvula proporcional	1

Os gráficos que serão apresentados a seguir utilizarão os dados da Tabela 4.9, que são os melhores parâmetros estimados, por cada algoritmo. A função objetiva para mono e multiobjetivo, corresponde ao cálculo do MSE da Equação 2.3 entre o sinal gerado e o sinal real obtido em campo.

4.2.1 Parâmetros do controlador

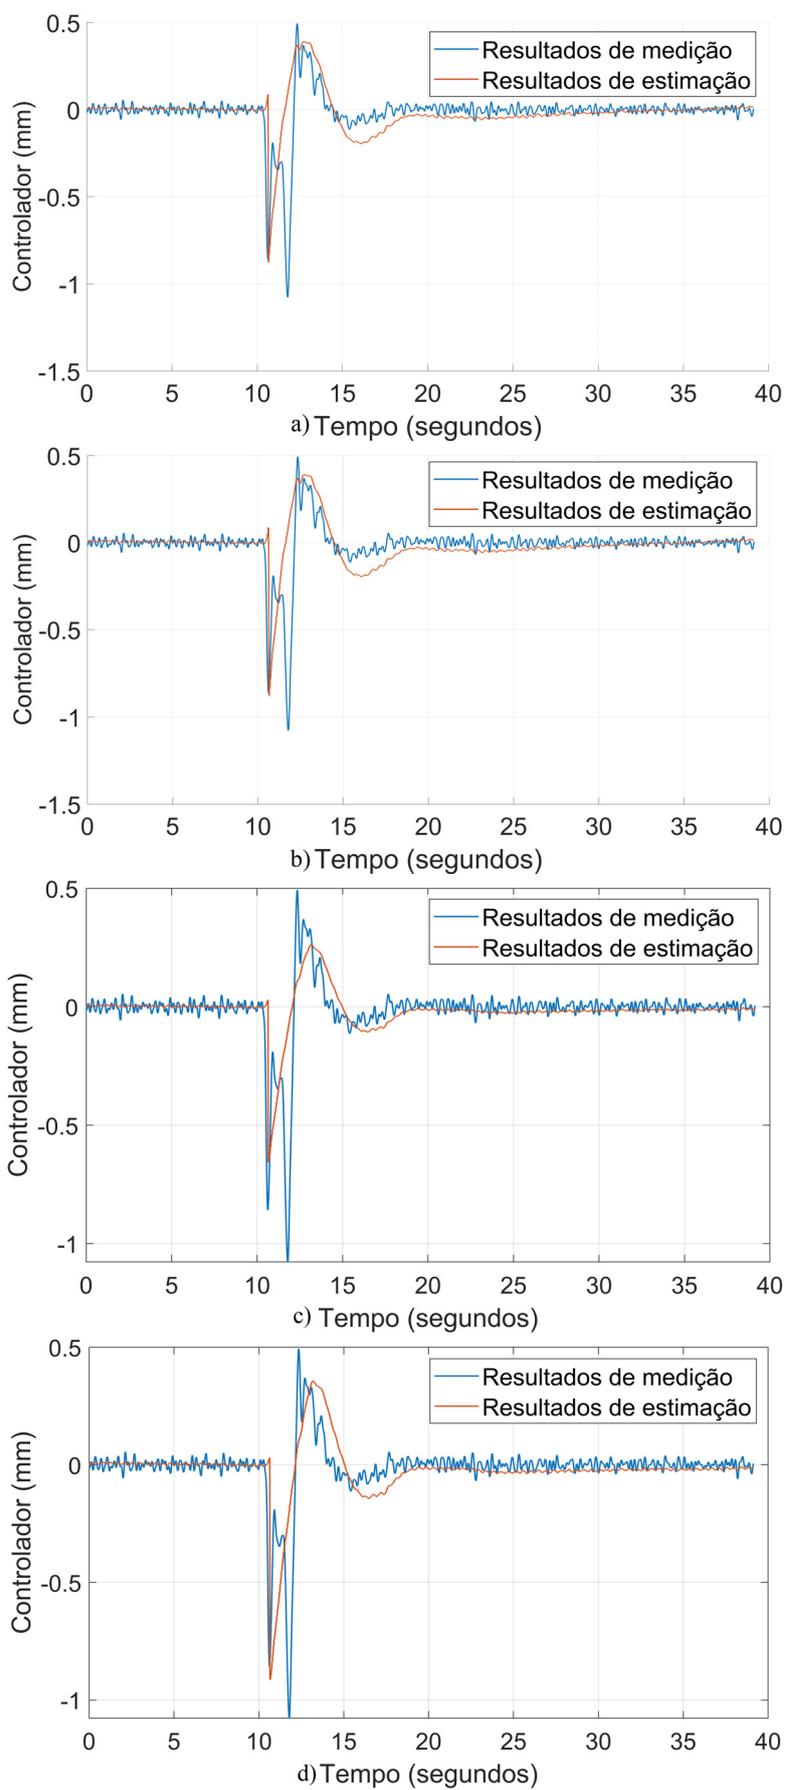


Figura 4.14: Resultados da tensão controlador. a) DE mono objetivo, b) GWO mono objetivo, c) DE multiobjetivo, d) GWO multiobjetivo

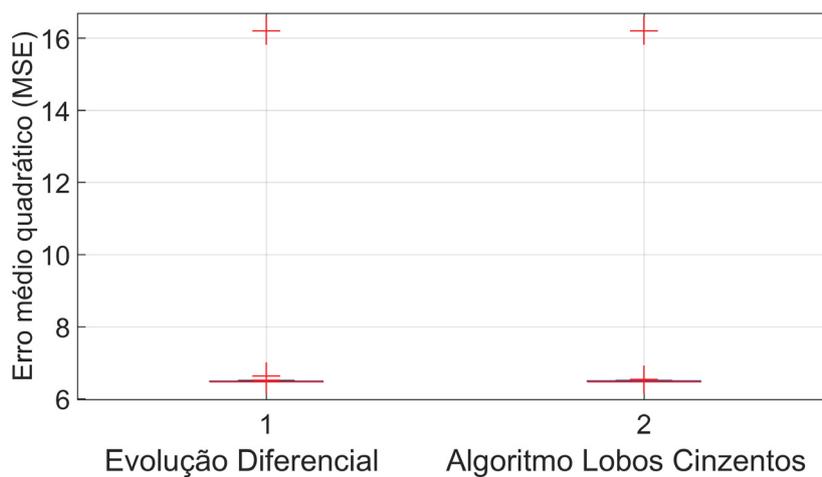


Figura 4.15: Resultados mono objetivos da Tensão do Controlador

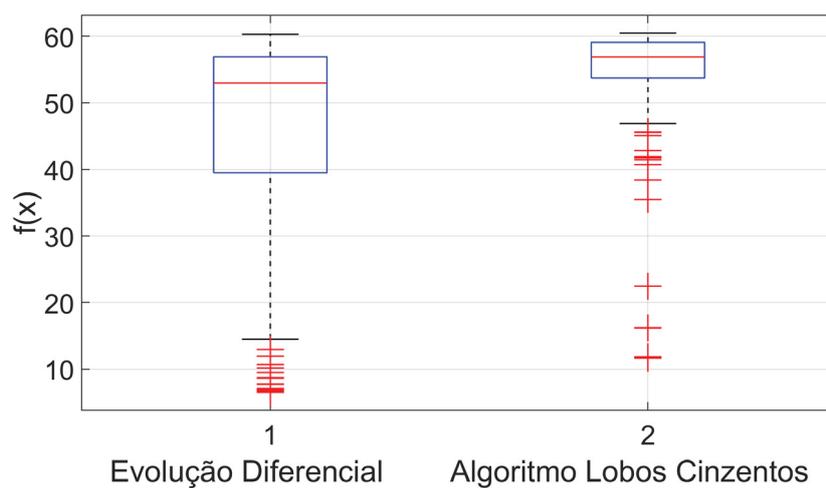


Figura 4.16: Resultados multiobjetivos da Tensão do Controlador

Observa-se que na figura 4.14 visualmente as respostas são bastante semelhantes, porém ao analisar as figuras 4.15 e 4.16, é constatado que os algoritmos no modo mono objetivo apresentam erros quadráticos menores em relação ao multiobjetivo.

4.2.2 Parâmetros da Válvula proporcional

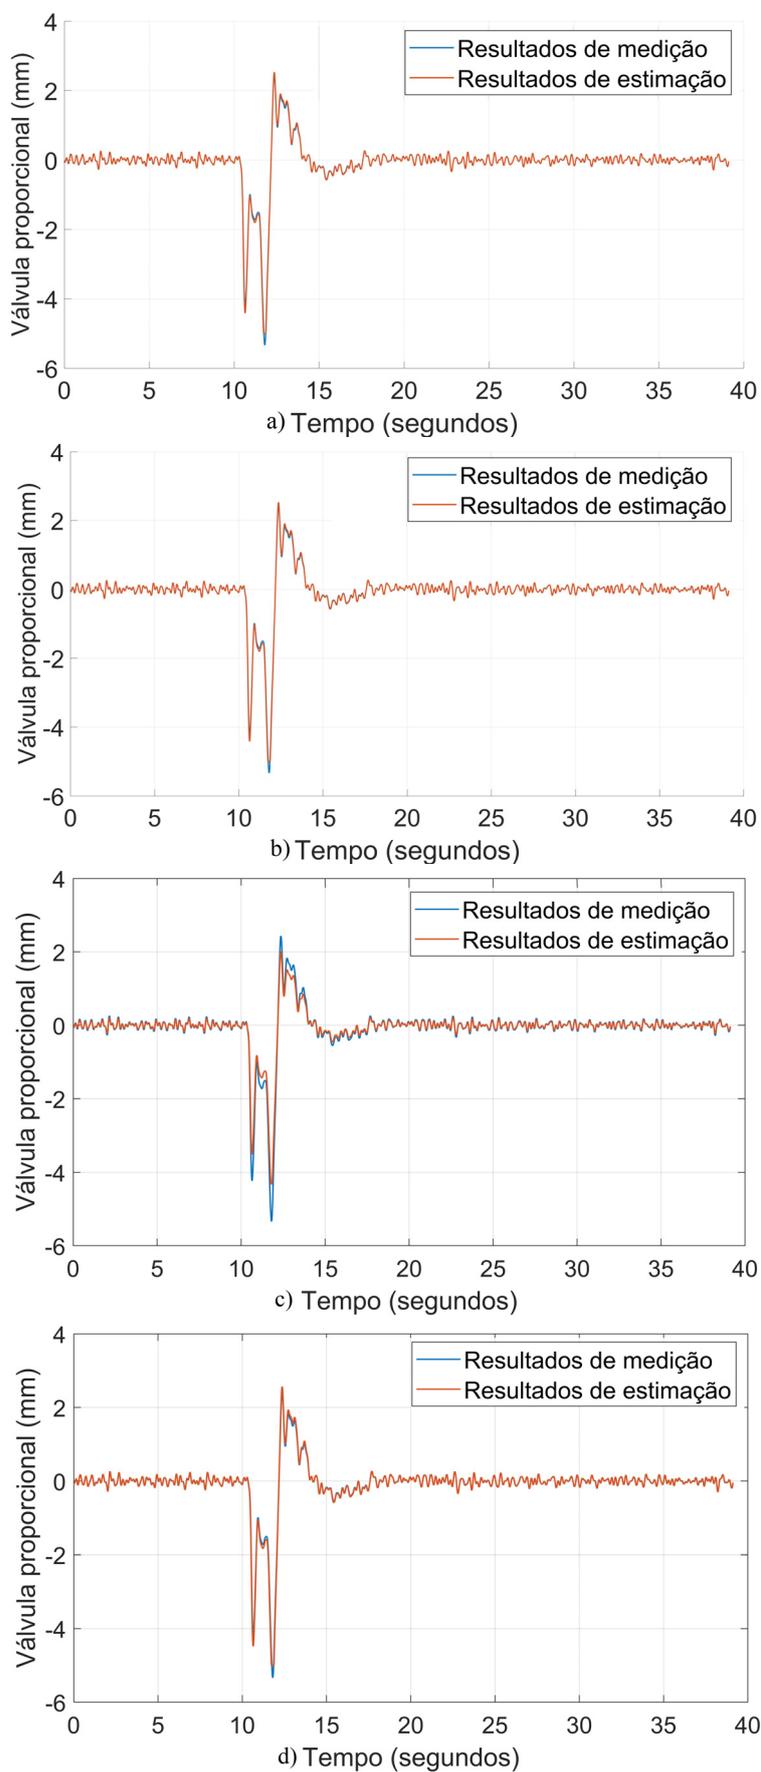


Figura 4.17: Resultados da válvula proporcional. a) DE mono objetivo, b) GWO mono objetivo, c) DE multiobjetivo, d) GWO multiobjetivo

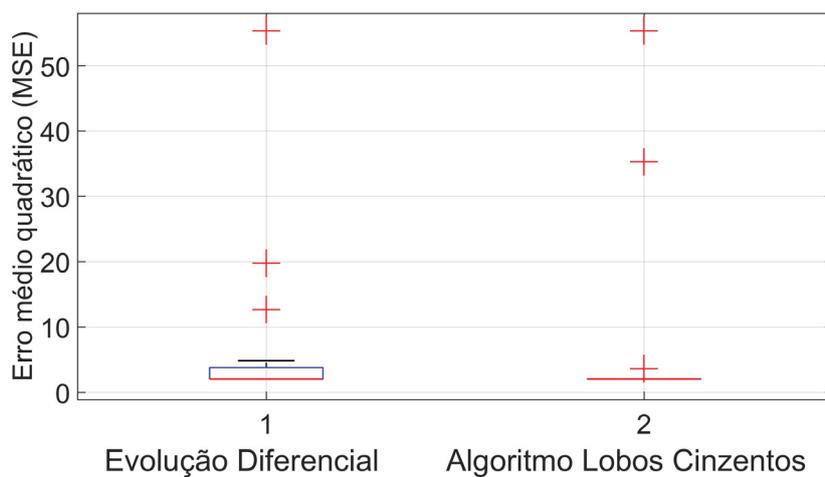


Figura 4.18: Resultados mono objetivos da Válvula Proporcional

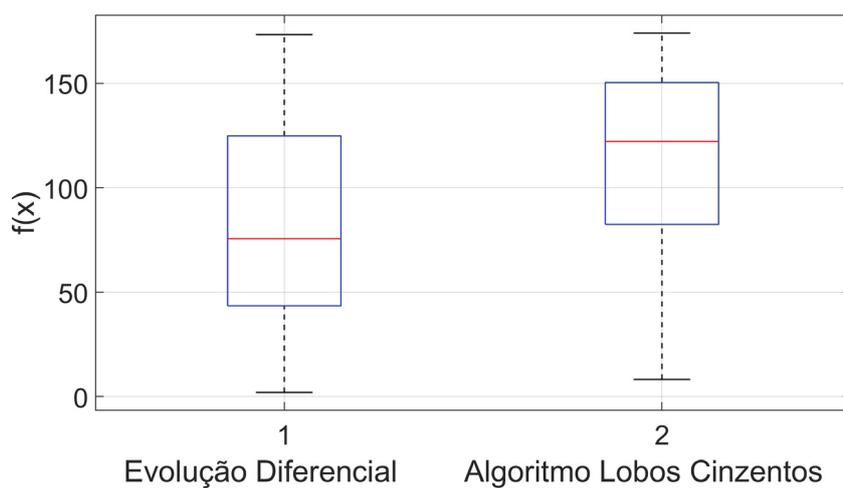


Figura 4.19: Resultados multiobjetivos da Válvula Proporcional

Observa-se que na figura 4.17 visualmente as respostas são bastante semelhantes, porém ao analisar as figuras 4.18 e 4.19, é constatado que os algoritmos no modo mono objetivo apresentam erros quadráticos menores em relação ao multiobjetivo.

4.2.3 Parâmetros da Válvula distribuidora

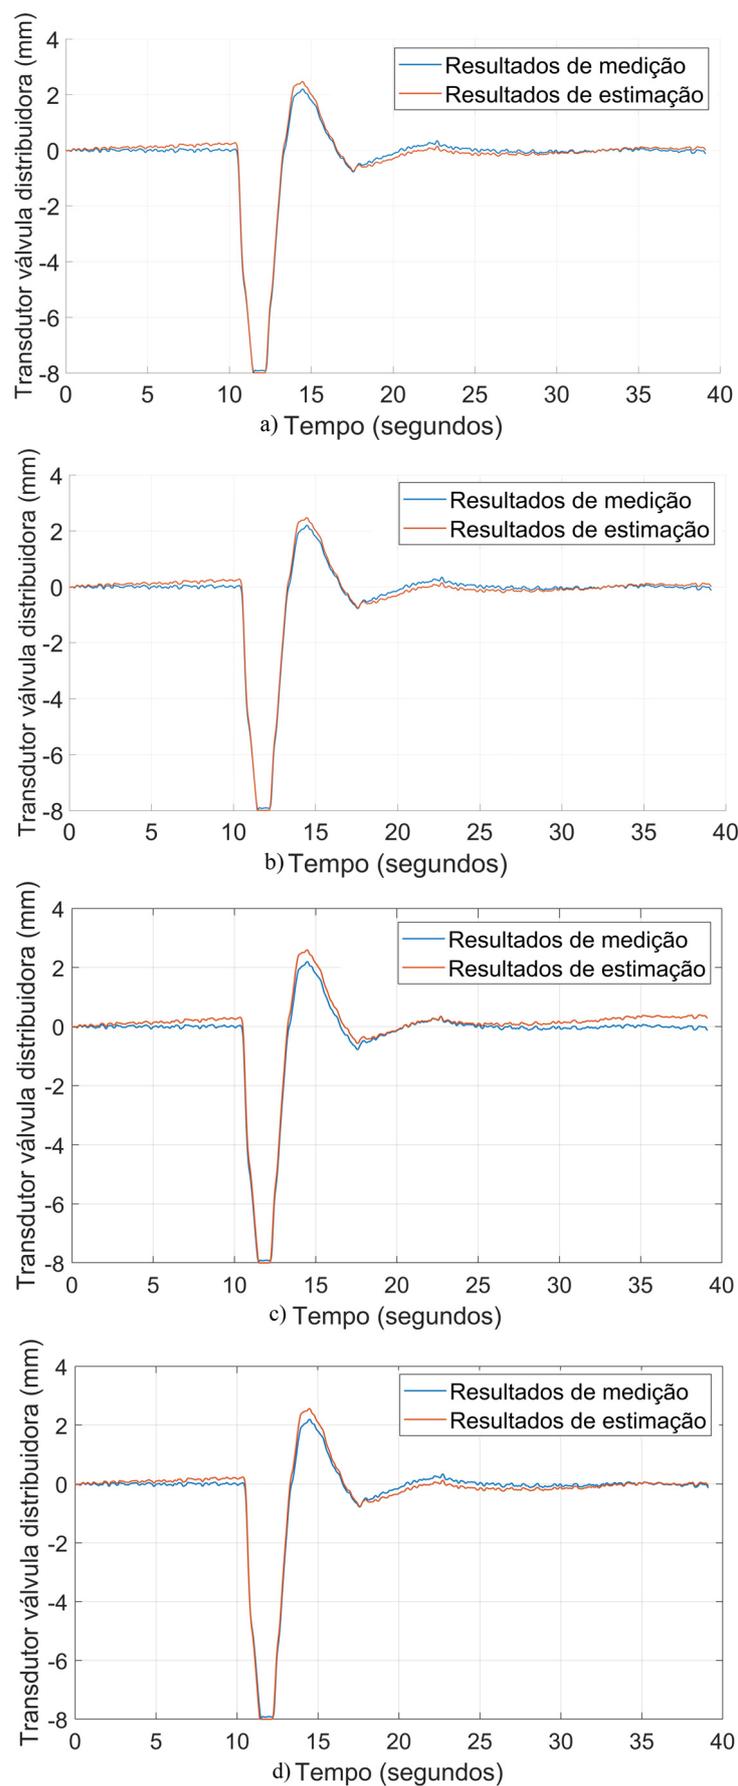


Figura 4.20: Resultados da válvula distribuidora. a) DE mono objetivo, b) GWO mono objetivo, c) DE multiobjetivo, d) GWO multiobjetivo

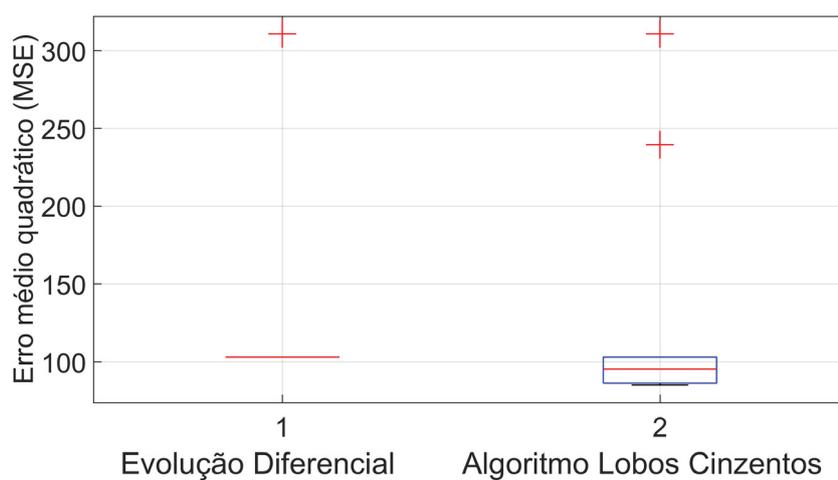


Figura 4.21: Resultados mono objetivos da Válvula Distribuidora

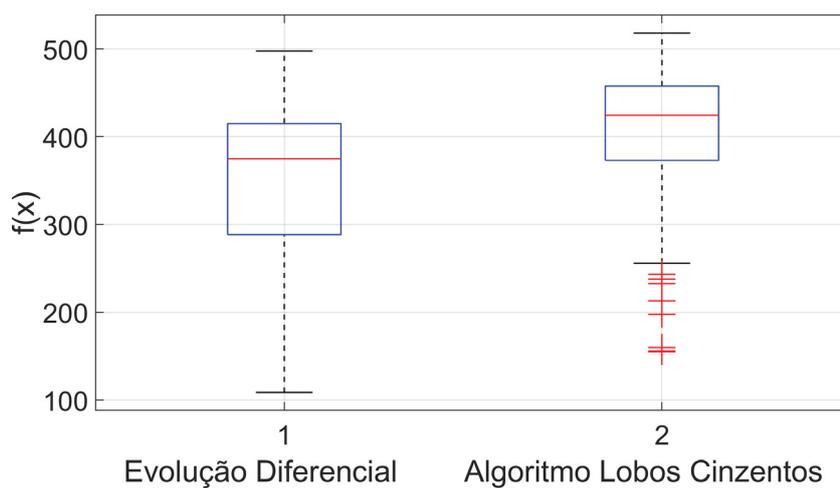


Figura 4.22: Resultados multiobjetivos da Válvula Distribuidora

Observa-se que na figura 4.20 visualmente as respostas são bastante semelhantes, porém ao analisar as figuras 4.21 e 4.22, é constatado que os algoritmos no modo mono objetivo apresentam erros quadráticos menores em relação ao multiobjetivo.

4.2.4 Parâmetros do Distribuidor

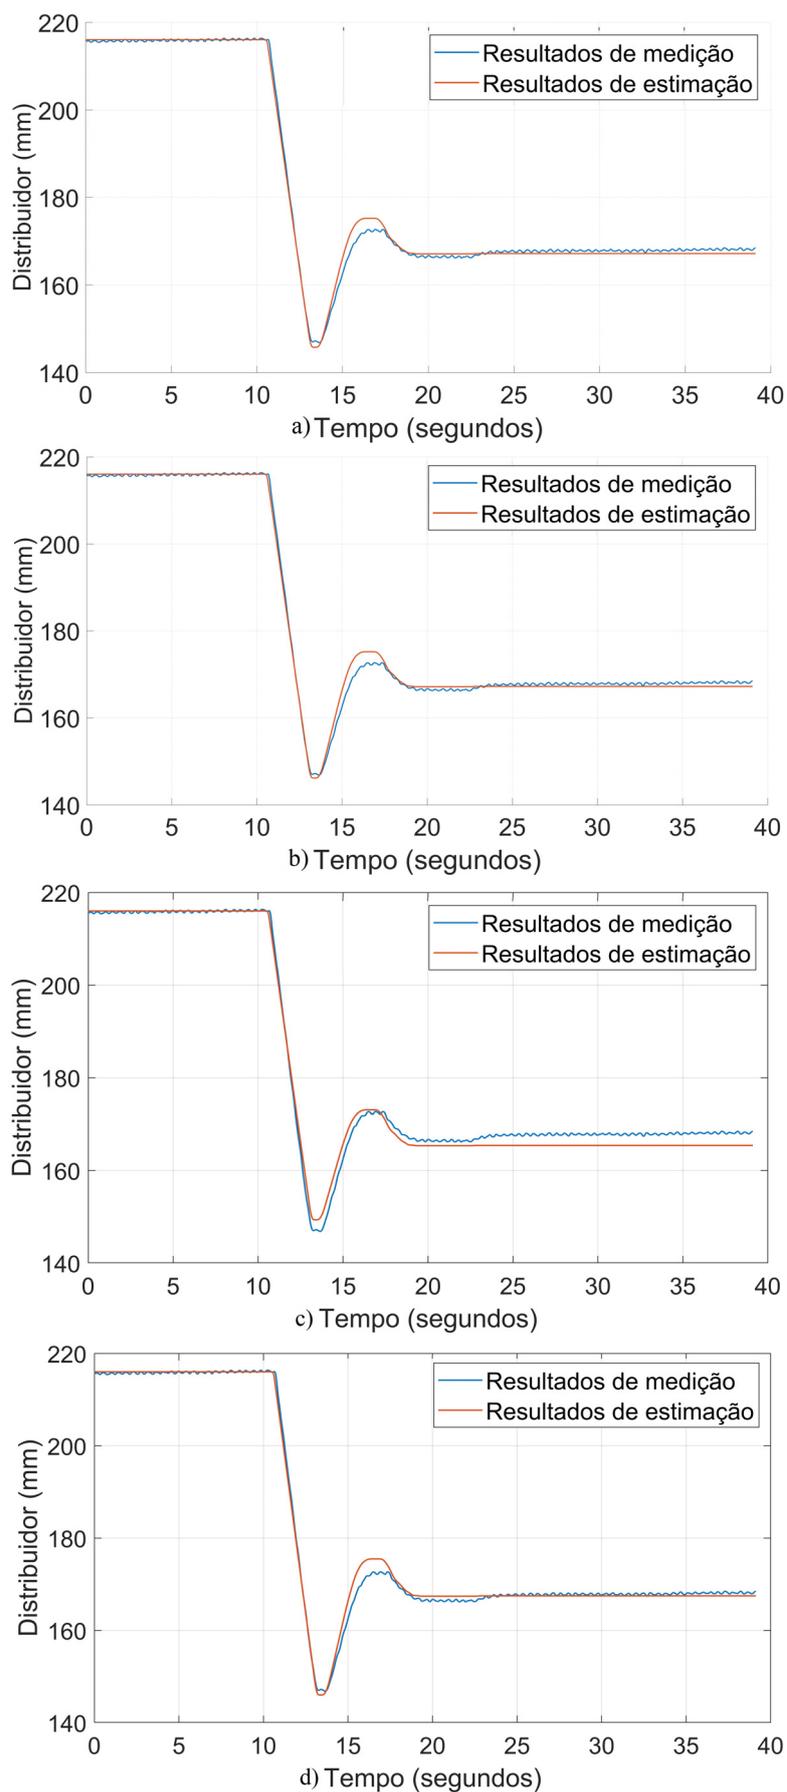


Figura 4.23: Resultados do distribuidor. a) DE mono objetivo, b) GWO mono objetivo, c) DE multiobjetivo, d) GWO multiobjetivo

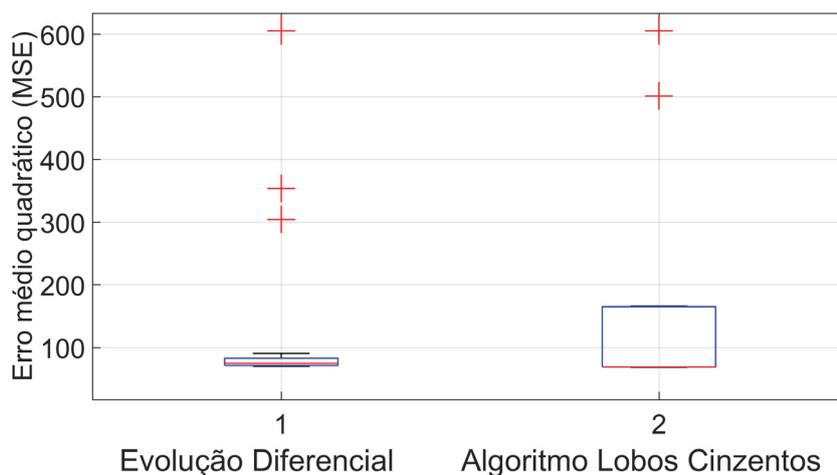


Figura 4.24: Resultados mono objetivos do Distribuidor

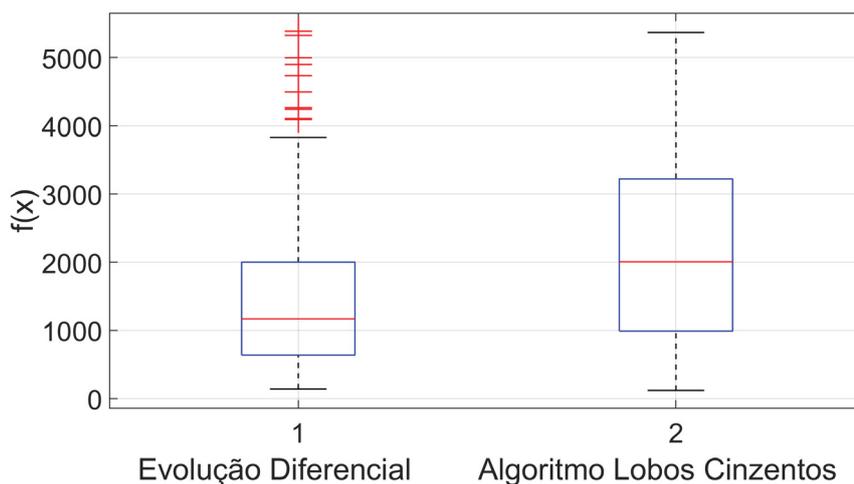


Figura 4.25: Resultados multiobjetivos do Distribuidor

Observa-se que na figura 4.23 visualmente as respostas são bastante semelhantes, porém ao analisar as figuras 4.24 e 4.25, é constatado que os algoritmos no modo mono objetivo apresentam erros quadráticos menores em relação ao multiobjetivo.

4.3 Análise dos parâmetros estimados

Da figura 4.26 a figura 4.29, são apresentados os boxplot dos parâmetros estimados pelas duas metaheurísticas em modo mono objetivo e multiobjetivo utilizadas.

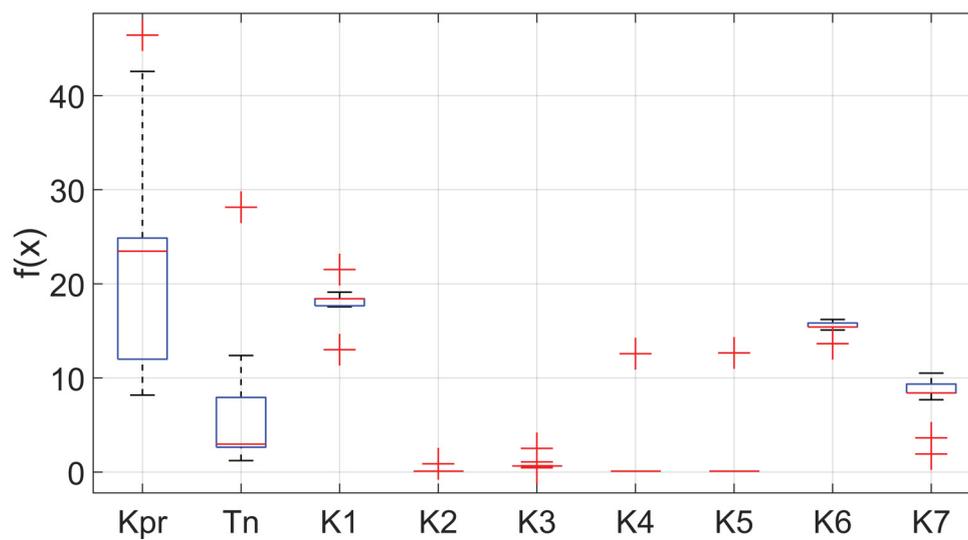


Figura 4.26: Parâmetros estimados com DE

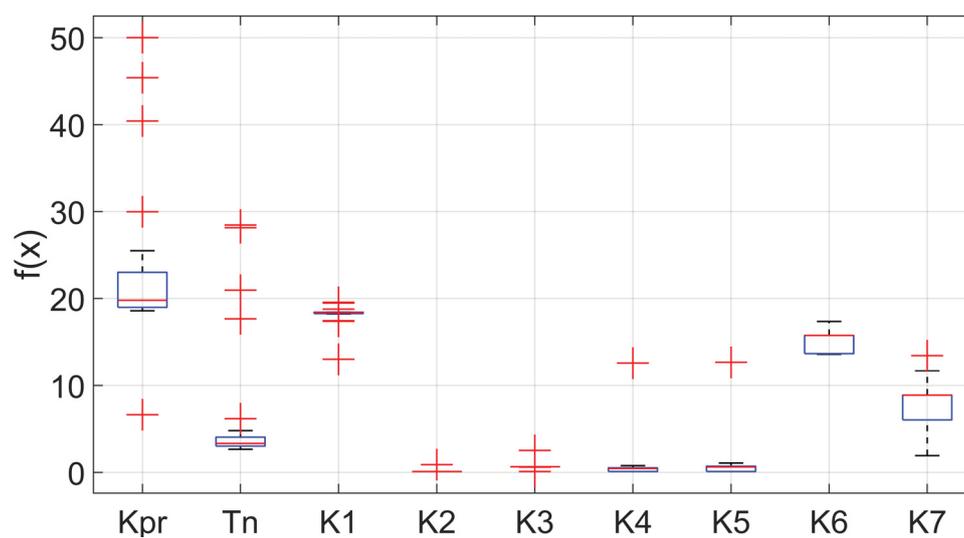


Figura 4.27: Parâmetros estimados com GWO

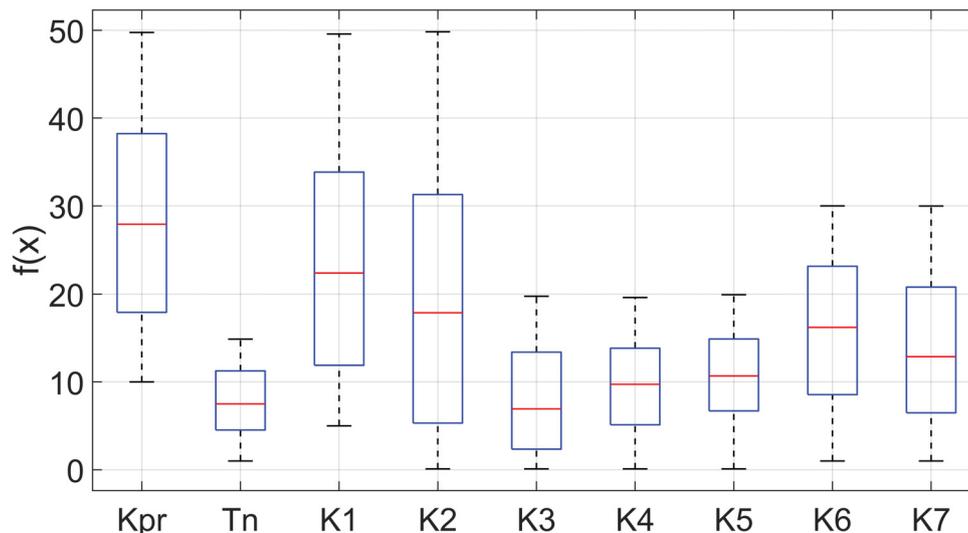


Figura 4.28: Parâmetros estimados com MODE

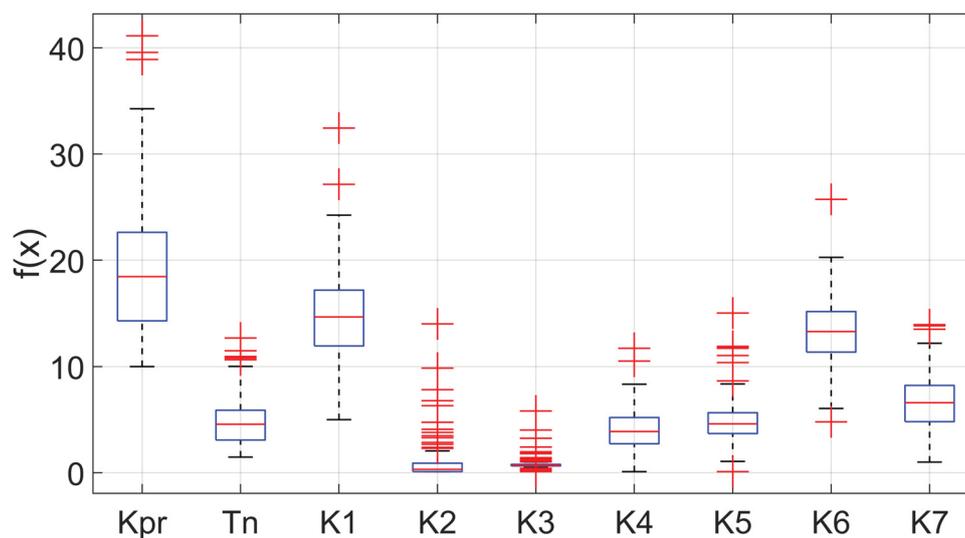


Figura 4.29: Parâmetros estimados com MOGWO

Nas figuras 4.26, 4.27 e 4.29, observa-se que a faixa de valores das variáveis estimadas são similares, porém os parâmetros estimados pelo algoritmo de otimização de lobos cinzentos possuem uma maior repetição da solução encontrada do que o algoritmo de evolução diferencial em modo mono objetivo. Enquanto na figura 4.28 tem maior repetibilidade dos parâmetros.

As figuras 4.30 a 4.33 apresentam a plotagem da saída da função objetiva (MSE) da tensão do controlador, válvula proporcional, válvula distribuidora e distribuidor.

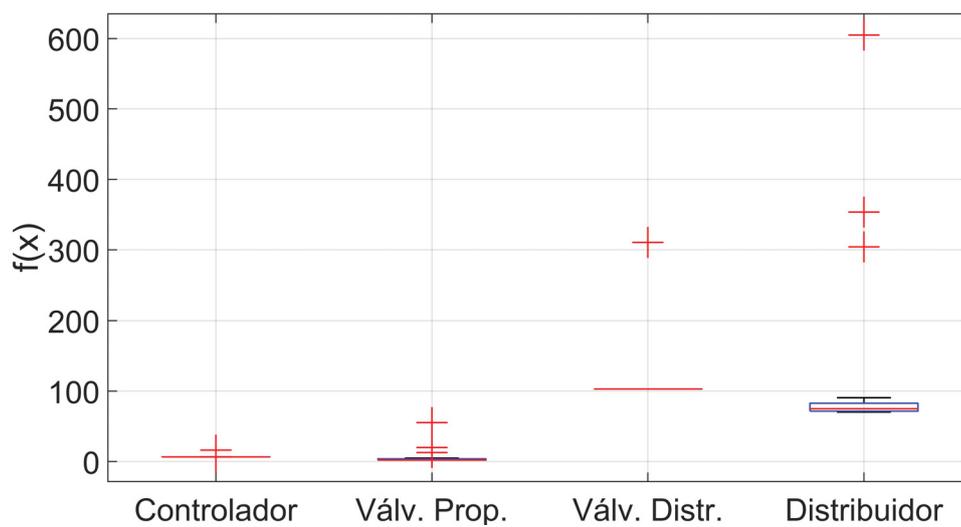


Figura 4.30: MSE de todas as funções, gerado com DE

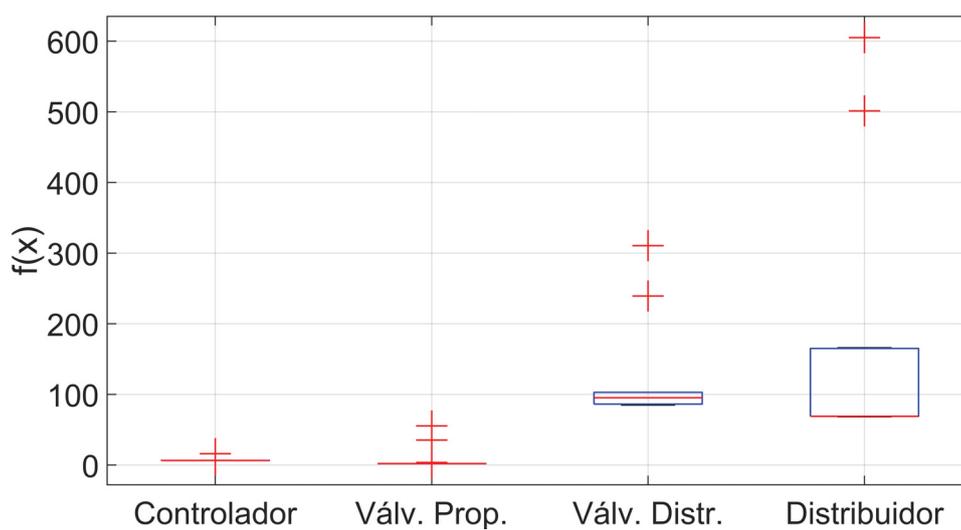


Figura 4.31: MSE de todas as funções, gerado com GWO

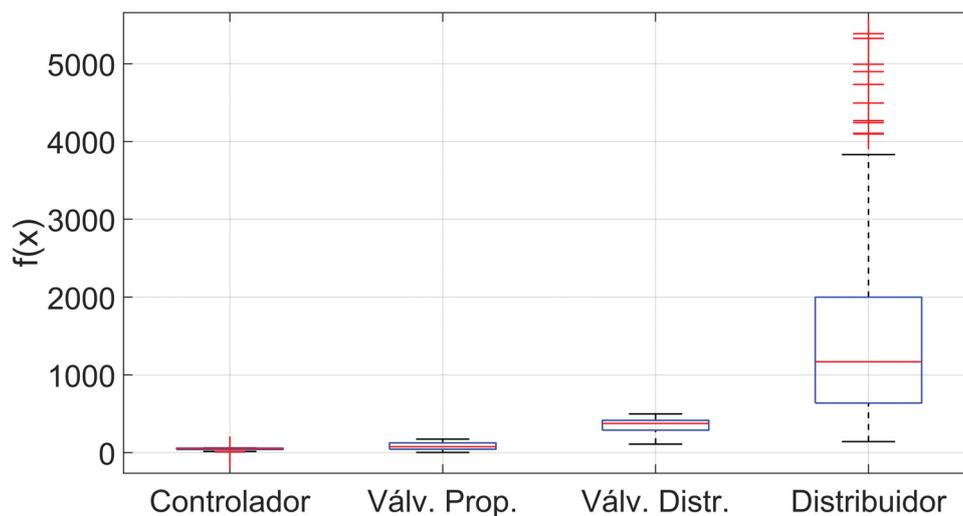


Figura 4.32: MSE de todas as funções, gerado com MODE

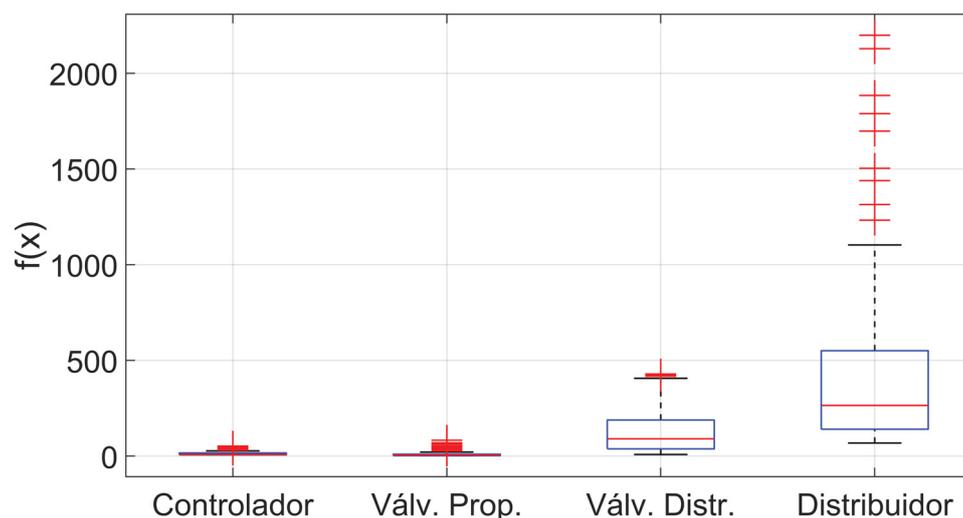


Figura 4.33: MSE de todas as funções, gerado com MOGWO

As figuras 4.30 a 4.33 apresentam valores médios similares, mas em relação aos valores com afastamento da linha vermelha (outliers) há variações.

Nas Tabelas 4.5 e 4.7 são apresentados os cálculos estatísticos resultantes da evolução diferencial em mono objetivo e multiobjetivo respectivamente, e nas Tabelas 4.6 e 4.8 são apresentado os resultados do algoritmo de otimização de lobos cinzentos em mono objetivo e multiobjetivo respectivamente. Os dados são referentes ao erro médio quadrático de cada estrutura, incluindo dados de média, desvio padrão, valor máximo e mínimo do conjunto de valores. Para fins de comparação, ambos algoritmos foram inicializados na primeira

rodada/iteração com os mesmos membros da população e com resultados bem distantes do resultado ótimo, para analisar seu comportamento e verificar suas melhorias a cada iteração.

Tabela 4.5: Cálculos estatísticos resultantes do Mono Objetivo DE

Estrutura	Média	Desvio padrão	Máximo	Minimo
Válvula proporcional	6,6612	10,2542	55,3021	2,0334
Transdutor da válvula distribuidora	108,0936	32,8324	310,5530	102,9023
Tensão controlador	6,7272	1,5362	16,1984	6,4712
Distribuidor	107,7435	104,0811	604,9986	70,1673

Tabela 4.6: Cálculos estatísticos resultantes do Mono Objetivo GWO

Estrutura	Média	Desvio padrão	Máximo	Minimo
Válvula proporcional	4,3169	9,7939	55,3021	2,0337
Transdutor da válvula distribuidora	121,6938	66,1850	310,5530	85,0795
Tensão controlador	6,7250	1,5364	16,1984	6,4712
Distribuidor	123,9551	108,7759	604,9986	68,4794

Tabela 4.7: Cálculos estatísticos resultantes do multiobjetivo DE

Estrutura	Média	Desvio padrão	Máximo	Minimo
Válvula proporcional	45,5399	16,6420	60,2847	6,5067
Transdutor da válvula distribuidora	85,7803	46,8518	173,3007	2,0339
Tensão controlador	349,4326	94,3801	497,4957	108,7290
Distribuidor	1534,1130	1247,8735	5388,3538	141,3670

Tabela 4.8: Cálculos estatísticos resultantes do multiobjetivo GWO

Estrutura	Média	Desvio padrão	Máximo	Minimo
Válvula proporcional	54,5860	7,7907	60,4610	11,6658
Transdutor da válvula distribuidora	113,6961	42,9053	174,0049	8,1914
Tensão controlador	403,7077	74,5694	517,9147	155,3177
Distribuidor	2189,1725	1374,5798	5368,5998	120,3416

A Tabela 4.9 apresenta os melhores parâmetros estimados para cada algoritmo, sendo estes os valores utilizados nas simulações que geraram os erros médios quadráticos apresentados nas figuras 4.14, 4.17, 4.20 e 4.23.

Tabela 4.9: Melhores parâmetros estimados / Algoritmos

	DE	GWO	MODE	MOGWO
Kpr	23,46708	18,58406	19,25423	23,6997
Tn	2,646748	3,34497	4,909288	4,395065
K1	18,41759	18,40826	11,77397	15,47372
K2	0,1	0,1	0,164553	0,171545
K3	0,650462	0,649967	0,540101	0,689548
K4	0,1	0,451334	4,934742	4,051212
K5	0,1	0,620513	5,850829	4,567936
K6	16,16229	15,82681	15,15291	15,91213
K7	9,542623	9,007168	7,435496	9,246524

Na Tabela 4.9, observa-se que há variação dos parâmetros estimados, mas a combinação do conjunto de valores, gera resultados similares nas simulações, devido o sistema ter um comportamento não linear.

Levando em consideração que este é um problema de minimização, significa que quanto menor o MSE, melhor será o resultado, sendo assim, o algoritmo DE mono objetivo apresentou o melhor valor para válvula proporcional, o algoritmo DE multiobjetivo obteve melhor valor para válvula distribuidora, o algoritmo GWO mono objetivo e DE mono

objetivo apresentaram o melhor valor para a tensão do controlador, e o GWO mono objetivo obteve o melhor valor para o distribuidor.

5 CONCLUSÃO

Estimar parâmetros de sistemas não lineares é uma tarefa desafiadora em função das diversas variações que podem ocorrer no processo real e no modelo utilizado.

Neste trabalho foram implementadas as metaheurísticas DE e GWO de forma multi e mono objetiva, sendo aplicada em problemas de benchmark, sendo que elas obtiveram resultados que validam a sua utilização. Com isto, elas foram então utilizadas no estudo de caso da turbina da UHE.

As metaheurísticas escolhidas neste trabalho mostraram-se adequadas aos objetivos propostos, pois conseguiram encontrar soluções que levaram a resposta do modelo próxima ao dos valores reais, no estudo de caso realizado. Para fins de comparação, foi analisado iteração a iteração de cada metaheurística, que demonstrou que o algoritmo de otimização de lobos cinzentos converge para soluções factíveis, e demonstrando um comportamento que obtém resultados ótimos em menos iterações em relação ao algoritmo de evolução diferencial.

Como trabalho futuro, sugere-se a realização das metaheurísticas rodando em paralelo, metaheurísticas híbridas e modelos que representem mais fielmente o controlador.

REFERÊNCIAS

PINTELON, R.; SCHOUKENS, J. **Mastering system identification in 100 exercises**. [S.l.]: Wiley, 2012. 103–104 p. ISBN 9780470936986.

LJUNG, L. **Ljung L System Identification Theory for User.pdf**. 1987. 475–476 p. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/0005109889900198>>.

LJUNG, L.; GLAD, T. **Modeling amp; Identification of Dynamic Systems**. [S.l.]: Studentlitteratur AB, 2016. ISBN 9789144116884.

ARROYO, J. E. C. HEURÍSTICAS E METAHEURÍSTICAS PARA OTIMIZAÇÃO COMBINATÓRIA MULTIOBJETIVO. 2002. Disponível em: <http://repositorio.unicamp.br/bitstream/REPOSIP/260313/1/Arroyo_JoseEliasClaudio_D.pdf>.

BILLINGS, S. a. **Nonlinear system identification**. [S.l.: s.n.], 2013. 564–568 p. ISSN 00051098. ISBN 9781119943594.

OLIVEIRA, J. L. de; LEANDRO, G. V.; BONFIM, M. J. d. C. **Os autores**. Curitiba: [s.n.], 2017.

EDITORS, S. et al. **Differential Evolution - A Practical Approach to Global Optimization**. [s.n.], 2008. 38–47 p. ISSN 1063-6560. ISBN 9783540209508. Disponível em: <<http://www.springerlink.com/index/X555692233083677.pdf>>.

HAUPT, R. L.; HAUPT, S. E.; HAUPT, R. L. **Practical genetic algorithms**. [S.l.]: John Wiley, 2004. 253 p. ISBN 0471671754.

OLIVEIRA, G. T. D. S. **Estudo e Aplicações da Evolução Diferencial**. 2006.

STORN, R.; PRICE, K. V. Differential Evolution - A simple and efficient adaptive scheme for global optimization over continuous spaces. p. 1–12, 1995. ISSN 1075-4946.

DAS, S.; SUGANTHAN, P. N. Differential evolution: A survey of the state-of-the-art. **IEEE Transactions on Evolutionary Computation**, v. 15, n. 1, p. 4–31, 2011. ISSN 1089778X.

GONG, W.; CAI, Z.; ZHU, L. An efficient multiobjective differential evolution algorithm for engineering design. **Structural and Multidisciplinary Optimization**, v. 38, n. 2, p. 137–157, 2009. ISSN 1615147X.

MIRJALILI, S.; MIRJALILI, S. M.; LEWIS, A. Grey Wolf Optimizer. **Advances in Engineering Software**, Elsevier Ltd, v. 69, p. 46–61, 2014. ISSN 09659978. Disponível em: <<http://dx.doi.org/10.1016/j.advengsoft.2013.12.007>>.

SAREMI, S.; MIRJALILI, S. Z.; MIRJALILI, S. M. Evolutionary population dynamics and grey wolf optimizer. **Neural Computing and Applications**, v. 26, n. 5, p. 1257–1263, 2015. ISSN 1433-3058. Disponível em: <<http://dx.doi.org/10.1007/s00521-014-1806-7>>.

EL-FERGANY, A. a.; HASANIEN, H. M. Single and Multi-objective Optimal Power Flow Using Grey Wolf Optimizer and Differential Evolution Algorithms. **Electric Power Components and Systems**, v. 43, n. 13, p. 1548–1559, 2015. ISSN 1532-5008.

TIJANI, I. B. et al. Optimization of an extended H-infinity controller for unmanned helicopter control using Multiobjective Differential Evolution (MODE). **Aircraft Engineering and Aerospace Technology**, v. 87, n. 4, p. 330–344, 2015. ISSN 0002-2667. Disponível em: <<http://www.emeraldinsight.com/doi/10.1108/AEAT-05-2012-0068>>.

CHEN, Z. et al. Application of multi-objective controller to optimal tuning of PID gains for a hydraulic turbine regulating system using adaptive grid particle swarm optimization. **ISA Transactions**, Elsevier, v. 56, p. 173–187, 2015. ISSN 00190578. Disponível em: <<http://dx.doi.org/10.1016/j.isatra.2014.11.003>>.

REYNOSO-MEZA, G. et al. Controller tuning using evolutionary multi-objective optimisation: Current trends and applications. **Control Engineering Practice**, Elsevier, v. 28, n. 1, p. 58–63, 2014. ISSN 09670661. Disponível em: <<http://dx.doi.org/10.1016/j.conengprac.2014.03.003>>.

CHEN, Z. et al. Improved gravitational search algorithm for parameter identification of water turbine regulation system. **Energy Conversion and Management**, Elsevier Ltd, v. 78, p. 306–315, 2014. ISSN 01968904. Disponível em: <<http://dx.doi.org/10.1016/j.enconman.2013.10.060>>.

Kundur P. **Power System Stability and Control**. [S.l.]: McGraw-Hill, 2010. 1176 p. ISBN 007035958X.

KHODABAKHSHIAN, A.; HOOSHMAND, R. A new PID controller design for automatic generation control of hydro power systems. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 32, n. 5, p. 375–382, jun 2010. ISSN 01420615. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061509001793>
<http://linkinghub.elsevier.com/retrieve/pii/S0142061509001793>>.

MUNOZ-HERNANDEZ, G. A.; MANSOOR, S. P.; JONES, D. I. **Modelling and controlling hydropower plants**. [S.l.]: Springer, 2013. ISBN 9781447122913.

OSINSKI, C. Contribuição para Modelagem do Contudo/Turbina e Proposta de PID Fuzzy para Controle de Velocidade em Usinas Hidrelétricas. p. 93, 2017.

Energy Development & Power Generation Committee. **IEEE Guide for the Application of Turbine Governing Systems for Hydroelectric Generating Units**. [S.l.: s.n.], 2011. ISSN 08998205. ISBN 9780738167022.

VILLEGAS PICO, H.; MCCALLEY, J. Modeling and analysis of speed controls in hydro-turbines for frequency performance. In: **NAPS 2011 - 43rd North American Power Symposium**. IEEE, 2011. p. 1–7. ISBN 9781457704192. ISSN 9781457704192. Disponível em: <<http://ieeexplore.ieee.org/document/6024847/>>.

AGUIRRE, L. A.; Barbosa Alves, G.; Vieira Corrêa, M. Steady-state performance constraints for dynamical models based on RBF networks. **Engineering Applications of**

Artificial Intelligence, Pergamon, v. 20, n. 7, p. 924–935, oct 2007. ISSN 09521976. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197606002193>>.

LJUNG, L. State of the art in linear system identification: Time and frequency domain methods. **IEEE**, v. 0, n. 2, p. 1–14, 2007. ISSN 0743-1619.

HIBBERT, D. Genetic algorithms in chemistry. **Chemometrics and Intelligent Laboratory Systems**, Elsevier, v. 19, n. 3, p. 277–293, jan 1993. ISSN 0169-7439. Disponível em: <<https://www.sciencedirect.com/science/article/pii/016974399380028G>>.

BOUSSAÏD, I.; LEPAGNOT, J.; SIARRY, P. A survey on optimization metaheuristics. In: **Information Sciences**. Elsevier, 2013. v. 237, p. 82–117. ISBN 0020-0255. ISSN 00200255. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020025513001588>>.

MIRJALILI, S. How effective is the Grey Wolf optimizer in training multi-layer perceptrons. **Applied Intelligence**, v. 43, n. 1, p. 150–161, 2015. ISSN 0924669X.

COELHO, A.; COELHO, L. d. S. Identificação de sistemas dinâmicos lineares. 2004.

CHANG, W. D. Nonlinear system identification and control using a real-coded genetic algorithm. **Applied Mathematical Modelling**, Elsevier, v. 31, n. 3, p. 541–550, mar 2007. ISSN 0307904X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0307904X05002519>>.

FERRARI, A. C. K. Identificação de Sistemas Multivariáveis por Evolução diferencial Otimizado por Lógica Nebulosa. **Statewide Agricultural Land Use Baseline 2015**, v. 1, 2015. ISSN 1098-6596. Disponível em: <<https://acervodigital.ufpr.br/handle/1884/41374>>.

SEVERINO, A. G. V.; ARAÚJO, F. M. U. de. Meta-heurísticas aplicadas a identificação de sistemas. 2015. Disponível em: <https://www.researchgate.net/profile/Alcemy_Severino/publication/320419180_Meta-heurísticas_aplicadas_a_identificacao_de_sistemas/links/59e49a55458515393d60fb3e/Meta-heurísticas_aplicadas-a-identificacao-de-sistemas.pdf>.

LOURENÇO, H. R.; MARTIN, O. C.; STÜTZLE, T. ITERATED LOCAL SEARCH. In: . [s.n.], 2003. Disponível em: <https://link.springer.com/content/pdf/10.1007/0-306-48056-5_11.pdf>.

PRICE, K. V. Differential evolution: a fast and simple numerical optimizer. **Fuzzy Information Processing Society, 1996. NAFIPS. 1996 Biennial Conference of the North American**, p. 524–527, 1996. Disponível em: <<papers2://publication/uuid/CC402C6E-3DE4-444F-B7E5-48EAC30623DB>>.

MEZURA-MONTES, E.; REYES-SIERRA, M.; Coello Coello, C. A. Multi-objective Optimization Using Differential Evolution: A Survey of the State-of-the-Art. **Advances in Differential Evolution**, p. 173–196, 2008. ISSN 1860949X. Disponível em: <http://link.springer.com/10.1007/978-3-540-68830-3_7>.

ADORIO, E.; DILIMAN, U. MVF multivariate test functions library in c for unconstrained global optimization. **geocities.ws**, p. 1–56, 2005. Disponível em: <<http://www.geocities.ws/eadorio/mvf.pdf>>.

MOLGA, M.; SMUTNICKI, C. Test functions for optimization needs. **Test functions for optimization needs**, n. c, p. 1–43, 2005. Disponível em: <<http://new.zsd.iar.pwr.wroc.pl/files/docs/functions.pdf>>.

DIXON, L. C. W.; SZEGÖ, G. P. **Towards Global Optimisation: Proceedings of a Workshop at the University of Cagliari, Italy, October 1974**. [S.l.]: North-Holland Pub. Co., 1975. 472 p. ISBN 0720424631.