Guilherme Resende Deus

**Otimização de Sistemas Hidrotérmicos de
Geração Por Meio de Meta-Heurísticas
Baseadas em Enxame de Partículas**

Brasil

29 de junho de 2017

**TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS
DE TESES E
DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG**

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do material bibliográfico: **Dissertação** **Tese**

2. Identificação da Tese ou Dissertação:

Nome completo do autor: Guilherme Resende Deus

Título do trabalho: Otimização de Sistemas Hidrotérmicos de Geração por Meio de Meta-Heurísticas Baseadas em Enxame de Partículas

3. Informações de acesso ao documento:

Concorda com a liberação total do documento **SIM** **NÃO**¹

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF da tese ou dissertação.

Assinatura do(a) autor(a)²

Data: 25 / 06 / 2019

¹Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente
- Submissão de artigo em revista científica
- Publicação como capítulo de livro
- Publicação da dissertação/tese em livro

²A assinatura deve ser escaneada.

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Deus, Guilherme Resende

Otimização de Sistemas Hidrotérmicos de Geração por Meio de Meta
Heurísticas Baseadas em Enxame de Partículas [manuscrito] /
Guilherme Resende Deus. - 2016.

53 f.: il.

Orientador: Prof. Dr. Gélson da Cruz Junior; co-orientador Dr.
Cassio Vinhal.

Dissertação (Mestrado) - Universidade Federal de Goiás, Escola
de Engenharia Elétrica, Mecânica e de Computação (EMC), Programa
de Pós-Graduação em Engenharia Elétrica e de Computação, Goiânia,
2016.

Bibliografia.

Inclui siglas, abreviaturas, símbolos, gráfico, tabelas, algoritmos,
lista de figuras, lista de tabelas.

1. sistemas hidrotérmicos de geração. 2. planejamento da operação.
3. pesquisa operacional. 4. algoritmos meta-heurísticos. 5. otimização
por enxame de partículas. I. Cruz Junior, Gélson da, orient. II. Título.

CDU 004.42

Ata de Dissertação de Mestrado

Ata da sessão de julgamento da Dissertação de Mestrado em Engenharia Elétrica e de Computação, área de concentração Engenharia de Computação, do candidato **Guilherme Resende Deus** realizada em 02 de dezembro de 2016.

Aos dois dias do mês de dezembro de dois mil e dezesseis, às 14:30 horas, na sala Caryocar Brasiliensis, bloco "A" da Escola de Engenharia Elétrica e de Computação (EMC), Universidade Federal de Goiás (UFG), reuniram-se os seguintes membros da Comissão Examinadora designada pela Coordenadoria do Programa de Pós-graduação em Engenharia Elétrica e de Computação: Os Doutores Gélson da Cruz Júnior – Orientador (EMC/UFG), Leonardo Nepomuceno - FEB/UNESP e Karina Rocha Gomes da Silva – EMC/UFG, para julgar a Dissertação de Mestrado de **Guilherme Resende Deus**, intitulada "Otimização de Sistemas Hidrotérmicos de Geração Por Meio de Meta-Heurísticas Baseadas em Enxame de Partículas", apresentada pelo Candidato como parte dos requisitos necessários à obtenção do grau de Mestre, em conformidade com a regulamentação em vigor. O Professor Doutor Gélson da Cruz Júnior Presidente da Comissão, abriu a sessão e apresentou o candidato que discorreu sobre seu trabalho, após o que, foi argüido pelos membros da Comissão na seguinte ordem: Leonardo Nepomuceno - FEB/UNESP e Karina Rocha Gomes da Silva. A parte pública da sessão foi então encerrada e a Comissão Examinadora reuniu-se em sessão reservada para deliberar. A Comissão julgou então que o Candidato, tendo demonstrado conhecimento suficiente, capacidade de sistematização e argumentação sobre o tema de sua Dissertação, foi considerado **aprovado** e deve satisfazer as exigências listadas na Folha de Modificação de Dissertação de Mestrado, em anexo a esta Ata, no prazo máximo de 60 dias, ficando o professor orientador responsável por atestar o cumprimento dessas exigências. Os membros da Comissão Examinadora descreveram as justificativas para tal avaliação em suas respectivas Folhas de Avaliação, anexas a esta Ata. Nada mais havendo a tratar, o presidente da Comissão declarou encerrada a sessão. Nos termos do Regulamento Geral dos Cursos de Pós-graduação desta Universidade, a presente Ata foi lavrada, lida e julgada conforme, segue assinada pelos membros da Comissão supracitados e pelo Candidato. Goiânia, 02 de dezembro de 2016.

Comissão Examinadora Designada:

Gélson da Cruz Júnior – Orientador (EMC/UFG) (Avaliação: APROVADO)

Leonardo Nepomuceno - FEB/UNESP (Avaliação: APROVADO)

Karina Rocha Gomes da Silva- EMC/UFG (Avaliação: APROVADO)

Candidato:

Guilherme Resende Deus

Guilherme Resende Deus

**Otimização de Sistemas Hidrotérmicos de Geração Por
Meio de Meta-Heurísticas Baseadas em Enxame de
Partículas**

Dissertação apresentada ao Programa de Pós-Graduação da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica e de Computação.

Universidade Federal de Goiás – UFG

Escola de Engenharia Elétrica, Mecânica e de Computação – EMC

Programa de Pós-Graduação

Orientador: Gélson da Cruz Junior

Coorientador: Cássio Vinhal

Brasil

29 de junho de 2017

Guilherme Resende Deus

Otimização de Sistemas Hidrotérmicos de Geração Por Meio de Meta-Heurísticas Baseadas em Enxame de Partículas

Dissertação apresentada ao Programa de Pós-Graduação da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica e de Computação.

Prof. Gélon da Cruz Júnior

Escola de Engenharia Elétrica, Mecânica e
de Computação – UFG

Prof^a. Karina Rocha Gomes da Silva

Escola de Engenharia Elétrica, Mecânica e
de Computação – UFG

Prof. Leonardo Nepomuceno

Faculdade de Engenharia - UNESP

Brasil

29 de junho de 2017

Agradecimentos

À minha família por ter me dado todas as condições para que eu possa estudar e me aperfeiçoar profissionalmente.

Ao Gélson, que me orientou e me apoiou nessa grande oportunidade de cursar uma pós-graduação stricto sensu.

À todos os professores da Escola de Engenharia Elétrica, Mecânica e de Computação, a quem devo minha formação como Engenheiro.

Resumo

Este trabalho objetiva encontrar soluções razoáveis para o problema de otimização de sistemas hidrotérmicos de geração por meio de meta-heurísticas baseadas em enxame de partículas. O problema proposto é complexo, dinâmico, não linear e apresenta algumas variáveis estocásticas. O estudo consistiu na implementação de algoritmos baseados em enxame de partículas, mais especificamente das variantes do algoritmo *Particle Swarm Optimization (PSO)*: *LSSPSO*, *ABeePSO* e *KFPSO*. Os algoritmos foram executados em um simulador de usinas que contém dados de oito usinas do *Sistema Interligado Nacional* durante o período de cinco anos. Os resultados foram comparados com o estudos que utilizam o algoritmo de Programação Não-Linear (PNL), e conclui-se que apesar de as meta-heurísticas apresentadas conseguirem obter um valor de Energia Armazenada Final igual ao PNL, não obtiveram um custo de geração equivalente ou inferior ao método de Programação Não-Linear.

Palavras-chaves: sistemas hidrotérmicos de geração, planejamento da operação, pesquisa operacional, algoritmos meta-heurísticos, otimização por enxame de partículas, enxame de partículas, LSSPSO, ABeePSO, KFPSO.

Lista de ilustrações

Figura 1 – Oferta interna de energia elétrica por fonte: 2015 (EPE 2016)	14
Figura 2 – Capacidade Instalada de Geração Elétrica: 2015 (Energia 2016)	14
Figura 3 – Decomposição Temporal do Planejamento de Sistemas Hidrotérmicos	18
Figura 4 – Mecanismo de geração, transmissão e distribuição de energia elétrica.	20
Figura 5 – Esquema Usina Hidrelétrica (Marques 2006)	21
Figura 6 – Gráfico Algoritmo PSO com sorteio normal	43
Figura 7 – Gráfico Algoritmo PSO com sorteio spline	43
Figura 8 – Gráfico Algoritmo LSSPSO com sorteio normal	44
Figura 9 – Gráfico Algoritmo LSSPSO com sorteio spline	45
Figura 10 – Gráfico Algoritmo ABeePSO com sorteio normal	46
Figura 11 – Gráfico Algoritmo ABeePSO com sorteio spline	47
Figura 12 – Gráfico Algoritmo KFPSO com sorteio spline	48

Lista de tabelas

Tabela 1 – Produção de energia primária por fonte: 2015 (EPE 2016)	13
Tabela 2 – Composição setorial por consumo de eletricidade: 2015 (EPE 2016) . .	13
Tabela 3 – Usinas hidrelétricas utilizadas para realização dos experimentos	42
Tabela 4 – Resultados com o Algoritmo PSO e sorteio normal	42
Tabela 5 – Resultados com o Algoritmo PSO e sorteio spline	42
Tabela 6 – Resultados com o Algoritmo LSSPSO e sorteio normal	44
Tabela 7 – Resultados com o Algoritmo LSSPSO e sorteio spline	44
Tabela 8 – Resultados com o Algoritmo ABeePSO e sorteio normal	45
Tabela 9 – Resultados com o Algoritmo ABeePSO e sorteio spline	46
Tabela 10 – Resultados com o Algoritmo KFPSO e sorteio spline	47

Lista de abreviaturas e siglas

ABC	Artificial Bee Colony
ABeePSO	Adaptative Bee and Particle Swarm Optimization
ABNT	Associação Brasileira de Normas Técnicas
APSO	Adaptative Particle Swarm Optimization
CEPEL	Centro de Pesquisas de Energia Elétrica
DET	Despacho Econômico Termelétrico
EPE	Empresa Brasileira de Energia Elétrica
KFPSO	Kalman Filter Particle Swarm Optimization
LSSPSO	Local Stochastic Search Particle Swarm Optimization
MME	Ministério de Minas e Energia
ONS	Operador Nacional do Sistema Elétrico
PDDE	Programação Dinâmica Dual Estocástica
PNL	Programação Não-Linear
PSO	Particle Swarm Optimization
PCV	Polinômio Cota Volume
PCF	Polinômio Cota Defluência
SIN	Sistema Interligado Nacional
TEP	Tonelada Equivalente de Petróleo
XML	Extensivel Markup Language

Sumário

1	INTRODUÇÃO	12
1.1	Organização do Trabalho	15
2	O PROBLEMA DE PLANEJAMENTO ENERGÉTICO DE SISTEMAS HIDROTÉRMICOS	16
3	UM MODELO PARA SISTEMAS HIDROTÉRMICOS DE GERAÇÃO	20
3.1	Geração Hidrelétrica	21
3.2	Geração Termelétrica	24
3.3	O Planejamento da Operação Energética	25
4	O AMBIENTE COMPUTACIONAL DE SIMULAÇÃO E OTIMIZAÇÃO	29
4.1	Algoritmos	30
5	ALGORITMO PARTICLE SWARM OPTIMIZATION	31
6	ALGORITMO LOCAL STOCHASTIC SEARCH PARTICLE SWARM OPTIMIZATION	34
7	ALGORITMO ADAPTATIVE BEE AND PARTICLE SWARM OPTIMIZATION	37
8	ALGORITMO KALMAN FILTER PARTICLE SWARM OPTIMIZATION	39
9	ESTUDOS DE CASO	41
9.1	Cenário dos Estudos de caso	41
9.1.1	PSO	42
9.1.1.1	Sorteio Normal	42
9.1.1.2	Sorteio Spline	42
9.1.2	LSSPSO	44
9.1.2.1	Sorteio Normal	44
9.1.2.2	Sorteio Spline	44
9.1.3	ABeePSO	45
9.1.3.1	Sorteio Normal	45
9.1.3.2	Sorteio Spline	46
9.1.4	KFPSO	47

9.1.4.1	Sorteio Normal	47
9.1.4.2	Sorteio Spline	47
10	CONCLUSÕES	49
10.1	Trabalhos Futuros	49
10.2	Publicações	50
	REFERÊNCIAS	51

1 Introdução

A humanidade se tornou bastante dependente da energia elétrica, pois por ser uma modalidade de energia bastante versátil, é utilizada para prover maior conforto às pessoas, como a viabilização da utilização cotidiana de inúmeros aparelhos eletrônicos e eletrodomésticos. É predominantemente utilizada para a iluminação das vias públicas, estabelecimentos comerciais e residências, além de manter em funcionamento as grandes indústrias das sociedades modernas. Essa dependência tem se acentuado devido ao acelerado desenvolvimento tecnológico, na medida em que mais equipamentos são construídos para funcionar por meio da eletricidade, acarretando em uma maior demanda por energia elétrica e exigindo maiores cuidados no planejamento e otimização dos recursos de geração.

O crescimento da população, a modernização da vida cotidiana e a crescente demanda pelos mais diversos tipos de aparelhos eletrônicos, além da incessante busca por crescimento em todos os setores da economia, conseqüentemente tem acarretado em um enorme aumento no consumo de energia elétrica, e tem tornado ainda mais crítico garantir o fornecimento contínuo e confiável dessa energia. Sendo assim, é imprescindível um bom gerenciamento dos recursos energéticos para que seja possível suprir toda a demanda e para que todo o sistema de geração, transmissão e distribuição opere com alguma garantia. Para um melhor planejamento do sistema de geração visando atender à crescente demanda, é necessário a realização de investimentos em ampliação e principalmente de otimização dos sistemas já existentes, além da realização de estudos de viabilidade para a construção de outros mais.

Segundo o “Relatório do Balanço Energético Nacional” de 2016 produzido pela EPE – Empresa de Pesquisa Energética (EPE 2016), que analisa dados do ano anterior, para suprir a demanda, a produção primária de energia no Brasil no ano de 2015 atingiu a marca de 286.471.000 tep - toneladas equivalente de petróleo, representando um aumento de 5.07% em relação ao ano anterior. Toda essa energia primária produzida, pode ser analisada na tabela 1 onde consta a produção de energia primária por fonte.

Já o consumo final por fonte de energia, considerando a energia produzida nacionalmente e a energia importada, e considerando também qualquer transformação anterior ao consumo final, apresenta uma composição percentual diferente, sendo 17,2% de eletricidade e 42,8% proveniente de fontes derivadas do petróleo. Os setores de transporte e industrial constam como os principais consumidores finais.

Apesar da produção primária de 30.938.000 tep proveniente de fontes hidráulicas, devido à importação e às transformações entre as mais variadas formas de energia em energia elétrica, o consumo total de eletricidade no ano de 2015 foi de 44.946.000 tep,

Fontes não renováveis	10³ tep	%
Petróleo	126.127	44,0
Gás Natural	34.871	12,2
Carvão Vapor	3.066	1,1
Carvão Metalúrgico	0	0,0
Urânio (U_3O_8)	512	0,2
Outras não renováveis	1.830	1
Fontes renováveis	10³ tep	%
Energia hidráulica	30.938	10,8
Lenha	24.519	8,6
Produtos da cana-de-açúcar	50.424	17,6
Outras renováveis	14.183	5,0
Produção primária total	10³ tep	%
Total	286.471	100

Tabela 1 – Produção de energia primária por fonte: 2015 (EPE 2016)

sendo o setor industrial e residencial os principais consumidores, conforme a composição setorial por consumo de eletricidade apresentado na tabela 2.

Setores	%
Setor energético	6,1
Residencial	25,1
Comercial	17,5
Público	8,2
Agropecuário	5,1
Transportes	0,4
Industrial	37,6

Tabela 2 – Composição setorial por consumo de eletricidade: 2015 (EPE 2016)

Considerando ainda o relatório produzido pela Empresa de Pesquisa Energética (EPE 2016), a geração de energia elétrica no Brasil em centrais de serviço público e autoprodutores atingiu 581,5 TWh em 2015, sendo que a geração hidráulica corresponde por 64,0% da oferta interna, e a geração térmica corresponde por 30,5%, conforme pode ser visto na figura 1, enquanto os percentuais de geração hidráulica e térmica mundial, medido no mesmo ano, foram respectivamente 17,3% e 67,2%. A capacidade total instalada e registrada pela EPE no referido ano, alcançou 140.858 MW. A entrada em operação de novas usinas, e de novas unidades de usina em expansão, em 2015, representou um acréscimo de 6.945 MW em relação ao ano anterior. A figura 2 apresenta a capacidade instalada de geração elétrica por fonte de energia.

Figura 1 – Oferta interna de energia elétrica por fonte: 2015 (EPE 2016)

Fonte	Nº Usinas	Potência instalada (MW)	Estrutura %	Potência média por usina
Hidrelétrica (*)	1.219	91.650	65,1	75
UHE	198	86.366	61,3	436
PCH	479	4.886	3,5	10
CGH	542	398	0,3	1
Gás	180	14.116	10,0	78
Gás Natural	146	12.428	8,8	85
Gás Industrial	34	1.688	1,2	50
Biomassa	543	13.336	9,5	25
Bagaço de Cana	394	10.532	7,5	27
Biogás	24	79	0,1	3
Outras	125	2.725	1,9	22
Petróleo	2.160	8.722	6,2	4
Nuclear	2	1.990	1,4	995
Carvão Mineral	13	3.390	2,4	261
Eólica	316	7.633	5,4	24
Solar	...	31	0,022	...
TOTAL	4.467	140.868	100,0	32
Importação contratada		5.850		
Disponibilidade total		146.718		

Nota: o nº total de usinas não inclui as solar distribuídas. A potência inclui solar distribuída.

Figura 2 – Capacidade Instalada de Geração Elétrica: 2015 (Energia 2016)

No Brasil, diferentemente da maioria dos países no mundo, existe uma alta disponibilidade de recursos hídricos, o que explica o grande percentual de geração hidráulica do total da oferta interna de energia elétrica. Além do fato de ser uma modalidade de energia renovável, e não contribuir para o aquecimento global, o país apresenta uma topologia favorável à construção de hidrelétricas e atualmente tem explorado apenas 30% de todo o seu potencial de geração. Apesar do alto investimento inicial e das discussões a respeito do impacto ambiental, a utilização de energia hidrelétrica no cenário Brasileiro pode ser

considerada vantajosa em relação as outras alternativas. Já a geração térmica, apesar de não apresentar as mesmas vantagens, é responsável por 30,5% da geração interna de eletricidade, e é responsável também por aproveitar as reservas de gás natural, carvão e derivados do petróleo, porém funciona em um regime de complementação do sistema hidrelétrico, devido ao seu alto custo de geração.

Inicialmente as usinas se concentravam na região sudeste, próximo aos grandes centros urbanos, com o desenvolvimento da transmissão e o aproveitamento da diversidade hidrológica existente entre as diversas bacias, hoje as usinas estão distribuídas por quase todo o território nacional. A grande extensão territorial do país, impôs um distanciamento entre as centrais geradoras e os grandes centros urbanos consumidores, o que acarretou na necessidade de construir extensas linhas de transmissão e um complexo arranjo de usinas e subestações distribuidoras. Esse grande sistema de geração, transmissão e distribuição de energia elétrica compreende o Sistema Interligado Nacional (SIN).

Segundo a Resenha Energética Brasileira 2016 ([Energia 2016](#)), produzido pelo Ministério de Minas e Energia, em 2015 o sistema de transmissão de energia elétrica do SIN alcançou 129,3 mil km de extensão, considerando a rede básica, 550 km relativos os sistemas isolados, além de 3.224 km do sistema de conexão de Itaipu. Toda a malha de é composta de trechos de transmissão nas seguintes tensões, em ordem crescente: 230 kV; 345 kV; 440 kV; 500 kV; e 750 Kv.

1.1 Organização do Trabalho

Esse trabalho apresenta na Seção 1 uma introdução sobre a importância da energia elétrica e apresenta o atual cenário de geração do país, apresentando a matriz energética nacional por fonte de energia, destacando a importância da geração hidráulica e ainda apresentando o que vem a ser o Sistema Interligado Nacional. A Seção 2 descreve o problema de planejamento de sistemas hidrotérmicos e apresenta o modelo de otimização em vigor. A Seção 3 apresenta o modelo matemático adotado para realização dos cálculos de simulação de sistemas hidrotérmicos de geração de energia elétrica. Na Seção 4 é descrito o modelo de otimização proposto além de apresentar a arquitetura de software adotada para a simulação de usinas, e o mecanismo de otimização. A Seção 5 apresenta o algoritmo Particle Swarm Optimization. A Seção 6 apresenta o algoritmo Local Stochastic Search Particle Swarm Optimization. A Seção 7 apresenta o algoritmo Adaptive Bee and Particle Swarm Optimization. A Seção 8 apresenta o algoritmo Kalman Filter Particle Swarm Optimization. A Seção 9 apresenta gráficos com resultados obtidos pelos algoritmos apresentados. Finalmente a Seção 10 apresenta conclusões acerca desse trabalho e propostas de trabalhos futuros.

2 O Problema de Planejamento Energético de Sistemas Hidrotérmicos

O objetivo de se otimizar sistemas de geração hidrotérmicos é garantir o atendimento da demanda de forma econômica e confiável. Com o planejamento da operação desses sistemas, é estabelecida uma estratégia que garanta a geração da demanda esperada ao menor custo possível. A estratégia deve contemplar o planejamento da operação diária, de acordo com os planejamentos da operação mensal e plurianual.

O ONS - Operador Nacional do Sistema Elétrico - é quem elabora a estratégia para cada unidade geradora do Sistema Interligado Nacional, e quem determina a meta de geração elétrica levando em consideração as restrições operativas, a demanda de carga, as disponibilidades energéticas e o custo de operação.

Dado o grande número de variáveis envolvidas e o alto grau de incerteza de algumas delas, o problema torna-se bastante complexo, e demanda um estudo minucioso. Algumas das estratégias para tentar solucionar o problema de planejamento é dividi-lo em problemas menores e parcialmente independentes com o intuito de facilitar a busca por uma solução adequada. Dessa forma, o estabelecimento de uma estratégia de geração para sistemas hidrotérmicos pode ser dividi-lo em duas etapas distintas: o planejamento da operação energética, que consiste na otimização da operação mensal de sistemas compostos por várias usinas, considerando apenas aspectos energéticos e restrições globais, e condicionado às particularidades do parque gerador a ser analisado; e o planejamento da operação elétrica, que consiste na otimização de metas de geração horárias das usinas considerando aspectos individuais não levados em conta na etapa de planejamento da operação energética.

O tamanho do horizonte de planejamento é quem vai determinar a classificação de cada uma dessas etapas. Para o estabelecimento da operação diária ou semanal, a variação do volume do reservatório de uma usina hidrelétrica, por exemplo, será desprezível, visto que o período analisado é muito curto para se observar uma variação significativa nessa variável. Porém se o período de planejamento contemplar um ano ou até vários anos, características como o regime de chuvas devem ser levadas em consideração, acrescentando um alto grau de incerteza ao planejamento.

O custo é o principal fator influenciador em toda a estratégia de geração. Como as hidrelétricas utilizam a força da água para mover as turbinas da usina, ou seja, sem custo adicional com combustíveis para a sua operação, elas serão sempre aproveitadas ao máximo, respeitando os limites da usina, os acordos governamentais, e restrições do uso da água por parte dessas usinas para o controle de cheias, navegação, irrigação e saneamento.

As termelétricas, como já mencionado, funcionam em regime de complementação das hidrelétricas devido ao seu alto custo de produção, pois sua operação é dependente de combustíveis, cujo o preço depende do tipo de combustível utilizado e da região em questão. Dessa forma o despacho das termelétricas é selecionado segundo uma ordem crescente de custo, de forma que o custo total para atendimento da carga seja mínimo. Esse despacho por ordem de custo é denominado DET - Despacho Econômico Termelétrico, e muitas vezes sofre impacto de contratos de geração termelétrica mínima que visam viabilizar a manutenção da usina, além da cobertura de gastos iniciais com a construção das mesmas.

Existe ainda um compromisso temporal das usinas hidrelétricas que está ligado às decisões de uso das águas presentes nos reservatórios. Esses recursos sofrem influência da vazão que chega aos reservatórios, que por sua vez sofre influência do regime pluviométrico da região em questão. Cada decisão de despacho tomada no presente, deve ser tomada a partir do estado atual do reservatório, da necessidade de geração e da previsão do volume de água que deve chegar ao reservatório no período planejado, caso contrário, pode comprometer as metas de geração, o cumprimento de restrições de operação ou restrições do uso da água no futuro. Essa preocupação com o estado atual e futuro dos reservatórios, além do grau da imprevisibilidade das afluições futuras que chegam aos reservatórios das usinas, dependentes das condições climáticas, adiciona ao problema um caráter estocástico, torna o problema bastante dinâmico, e exige um planejamento minucioso.

Num parque termelétrico as usinas são praticamente independentes entre si, porém em usinas hidrelétricas pertencentes a uma mesma bacia hidrográfica existe também um compromisso espacial entre elas, pois há um acoplamento operativo de tal forma que a decisão tomada por uma delas pode influenciar as demais. Uma usina situada a jusante de outra, sofre diretamente os efeitos das decisões de tomadas na usina a montante. Quando num mesmo curso d'água existem várias usinas sequencialmente, os efeitos das decisões da usina mais a montante são estendidos a todas as demais, de tal forma que a usina mais a jusante fica impossibilitada de realizar um planejamento autônomo, exigindo assim que um planejamento único seja elaborado para todo o sistema.

Os detalhes em relação à transmissão, como a distância entre as usinas e os grandes centros consumidores, os índices de perdas na transmissão, e a heterogeneidade também devem ser analisados para que seja possível operar de forma eficiente, o que agrega ainda mais complexidade ao problema. Além disso, as funções de geração hidráulica bem como as de custo da complementação térmica, são funções não lineares, tornando inviável a adoção de um único modelo matemático para o problema de planejamento energético de sistemas hidrotérmicos. A sugestão de Pereira, 1985 ([PEREIRA 1985](#)), foi a decomposição do planejamento em etapas divididas em diferentes escalas de tempo, de forma que cada período do horizonte de planejamento possa considerar apenas aspectos relevantes em detrimento de outros menos importantes para o período analisado, conforme apresentado

na figura 3.

Figura 3 – Decomposição Temporal do Planejamento de Sistemas Hidrotérmicos

Segundo o site da CEPEL (Centro de Pesquisas de Energia Elétrica) (CEPEL 2016) atualmente no Brasil são utilizados três modelos de otimização de sistemas hidrotérmicos para o planejamento da geração de energia elétrica, onde cada um desses modelos adota um horizonte de planejamento distinto e considera apenas os aspectos relevantes para o período planejado, com diferentes graus de detalhamento para a representação do sistema. São eles: o NEWAVE, o DECOMP e o DESSEM.

No Planejamento de Longo Prazo, o período a ser planejado compreende alguns anos, com discretização mensal, para sistemas constituídos de grandes reservatórios e com grande capacidade de regularização. Como já mencionado, para períodos longos o grau de incerteza das afluições é alto, assim, a estocasticidade de suas vazões não pode ser desprezada e a estratégia adotada deve contar com certa margem de segurança para a utilização dos recursos energéticos armazenados. No Brasil o NEWAVE (NEWAVE 2016) é o modelo responsável por esse planejamento com um horizonte de até 5 anos, com discretização mensal. Esse modelo utiliza a Programação Dinâmica Dual Estocástica (PDDE) e visa determinar as metas de geração para cada usina durante as várias etapas do período em questão. As metas devem atender a demanda e minimizar o valor esperado do custo de operação, que é composto pelo custo atribuído às interrupções de fornecimento de energia (NEWAVE 2013) e pelo custo variável do combustível que sustenta a operação das usinas termoeletricas.

O Planejamento de Médio Prazo abrange um horizonte de alguns meses, com discretização mensal ou semanal. Com um grau de incerteza razoável, o problema é tratado como determinístico, e tem como objetivo a determinação de uma política de operação individualizada, que considere o acoplamento hidráulico e possíveis diversidades

hidrológicas entre os rios. Com o modelo DECOMP (DECOMP 2016) são realizados planejamentos de até 12 meses, determinando as metas de geração para cada usina de forma a minimizar o custo de operação ao longo desse período. O modelo NEWAVE também é capaz de realizar o planejamento com o horizonte de alguns meses.

O Planejamento de Curto Prazo abrange um horizonte de algumas horas a uma semana, e o objetivo é a desagregação de metas de geração semanais ou mensais previamente fornecidas, considerando todos os aspectos energéticos, hidráulicos e elétricos não levados em conta nas etapas anteriores. No Brasil o modelo DESSEM é o responsável pelo planejamento de médio/curto prazo. Ele desenvolve modelos computacionais relacionados à otimização da programação diária da operação de sistemas termoeletricos, considerando um grande nível de detalhes peculiares a cada sistema, e agregando em um única modelagem todo o problema de despacho hidráulico, termelétrico e fluxo de potência ótimo (DESSEM 2016).

3 Um Modelo para Sistemas Hidrotérmicos de Geração

O mecanismo de produção de energia elétrica compreende a geração, a transmissão e a distribuição dessa energia gerada até os consumidores finais. A geração é a parte do sistema responsável pela efetiva produção de energia elétrica por meio das mais variadas fontes, sendo as mais comuns as fontes hidrelétricas que utilizam a energia potencial hidráulica, e as fontes termelétricas que utilizam a energia da queima de combustíveis fósseis, como carvão, gás, óleo, ou ainda a energia da fissão nuclear. A transmissão de energia é feita através de longas linhas de transmissão, geralmente de alta voltagem, que percorrem todo o território nacional e é responsável pela interligação das fontes geradoras aos principais centros consumidores. A distribuição compreende a malha que sai das subestações e que cobre principalmente as cidades para distribuir energia para cada unidade consumidora. A figura 4 ilustra toda a cadeia de geração, transmissão e distribuição de energia elétrica.

Figura 4 – Mecanismo de geração, transmissão e distribuição de energia elétrica.

3.1 Geração Hidrelétrica

Conforme mencionado, a geração hidrelétrica é responsável por 64% da oferta interna de energia elétrica. O processo dessa modalidade de geração baseia-se na transformação de energia potencial hidráulica em energia elétrica, e esse processo inicia-se através do represamento de água de rios ou lagos em um grande reservatório, com o auxílio de uma barragem. Com o acúmulo de água no reservatório próximo à barragem, criam-se diferenças de altura que provocam o acúmulo de energia potencial hidráulica. Essa energia potencial é uma das formas de energia renováveis mais abundante na natureza, e no Brasil há ainda um grande potencial não explorado localizados principalmente nas regiões Norte e Centro-Oeste.

O processo segue com a água do reservatório sendo liberada através de tubulações de adução que conectam o reservatório a uma casa de força onde essa água é utilizada para girar as pás das turbinas, nas quais a energia de pressão dinâmica desenvolvida no percurso pela tubulação é convertida em energia cinética de rotação. As turbinas estão conectadas a geradores que, postos em movimento contínuo, convertem a energia cinética em energia elétrica. Depois de passar pelas turbinas, a água retorna ao rio através do canal de fuga. A usina possui vertedouro, dispositivo que permite a liberação de água do reservatório sem passar pela casa de força (Cicogna e Soares 1999). A figura 5 ilustra o mecanismo de uma usina hidrelétrica.

Figura 5 – Esquema Usina Hidrelétrica (Marques 2006)

As variáveis envolvidas no processo de geração hidrelétrica são:

- x - volume do reservatório em hm^3 ;

- $x_{util} = (\bar{x} - \underline{x})$ - volume útil do reservatório em hm^3 ;
- $\underline{x}$ - volume mínimo do reservatório em hm^3 ;
- $\bar{x}$ - volume máximo do reservatório em hm^3 ;
- u - defluência em m^3/s ;
- q - engolimento em m^3/s ;
- v - vertimento em m^3/s ;
- $h_{mon}(x)$ - nível do reservatório em m ;
- $h_{jus}(x)$ - nível do reservatório em m ;
- $h(x, u) = h_{mon}(x) - h_{jus}(u)$ - altura de queda bruta em m ;
- pc - perda de carga nas tubulações em m ;
- $h_{liq}(x, u) = h_{mon}(x) - h_{jus}(u) - pc$ - altura da queda líquida em m

A variável x representa a quantidade de água armazenada no reservatório, ou seja o volume. O volume útil x_{util} do reservatório é a diferença entre os volumes máximo $\bar{x}$ e o mínimo $\underline{x}$ para a operação normal da usina.

A variável q representa a vazão turbinada pela usina. Ela é limitada pelo engolimento máximo da usina $\bar{q}$, que é o valor da vazão turbinada que produz a potência máxima da usina para uma data altura de queda líquida.

A variável v representa o vertimento, que é a vazão que é defluída pela usina sem passar pela casa de máquinas.

A soma da defluência total da usina é representada pela variável u através da seguinte equação 3.1:

$$u = q + v \quad (3.1)$$

A perda de carga pc nas tubulações é causada principalmente pelo atrito que existe nas tubulações e age como um redutor na altura de queda bruta do reservatório, sendo descontada desta para se obter a altura de queda líquida.

O nível do reservatório é chamado de *cotamontante* $h_{mon}(x)$, enquanto o nível do canal de fuga é chamado de *cotajusante* $h_{jus}(u)$. Este níveis são funções do volume e da defluência respectivamente e, no caso brasileiro, são adotados representações polinomiais para estas relações, denominadas *polinômio cotavolume* (PCV) e *polinômio cota – defluência* (PCF).

A função de produção hidráulica de uma usina($p(\cdot)$) pode ser deduzida a partir da variação incremental da energia potencial armazenada no reservatório conforme 3.2:

$$de_p = dm \cdot g \cdot h \quad (3.2)$$

onde dm é uma variação incremental da massa de água armazenada no reservatório, g é a aceleração da gravidade e h é a altura de queda desde reservatório. Considerando também o peso específico da água p e transformando o volume de água em vazão no tempo:

$$de_p = p \cdot q \cdot dt \cdot g \cdot h \quad (3.3)$$

A transformação de energia potencial em energia elétrica será dada pelo rendimento do conjunto turbina-gerador:

$$e_e = n \cdot e_p \quad (3.4)$$

Assim:

$$de_e = n \cdot p \cdot q \cdot dt \cdot g \cdot h \quad (3.5)$$

Transformando esta energia em potência: ($p = \frac{de}{dt}$):

$$p = n \cdot p \cdot q \cdot g \cdot h \quad (3.6)$$

A altura de queda aqui considerada é a altura de queda líquida do reservatório, ou seja, a altura de queda bruta menos as perdas de carga.

$$p = n \cdot p \cdot q \cdot g \cdot (h_{mon}(x) - h_{jus}(u) - pc) \quad (3.7)$$

Englobando em uma constante k o rendimento do conjunto turbina-gerador, a aceleração da gravidade, e o peso específico da água, pode-se escrever a função de geração hidráulica da seguinte maneira:

$$p(x, u) = k \cdot (h_{mon}(x) - h_{jus}(u) - pc) \cdot q \quad (3.8)$$

Na análise desta função dois pontos importantes devem ser considerados:

- a função é decrescente em relação à u , enquanto $u < q_{max}$ (aumento da turbinagem);
- a produtividade das usinas aumenta com o volume armazenado nos reservatórios (aumento da altura de queda líquida).

O engolimento máximo da usina geralmente é calculado considerando-se que a usina pode possuir vários conjuntos de máquinas. Cada conjunto é formado por máquinas com a mesma potência e engolimento máximo. Para toda a usina, o engolimento máximo total será a soma dos engolimentos de cada conjunto, assim:

$$\bar{q} = \sum_{n=1}^{NCM} \sum_{m=1}^{NMC} \bar{q}_{nm} \quad (3.9)$$

onde:

- NCM - número de conjuntos de máquinas da usina i ;
- NMC - número de máquinas do conjunto n ;
- $\bar{q}_{nm}$ - engolimento máximo da máquina m do conjunto n .

Ao modelar uma usina hidroelétrica, toda a água que converge para o seu reservatório, decorrente de chuvas, vazão natural do rio e seus afluentes e de usinas a montante é reunida na variável vazão afluente y . Num sistema de várias usinas, define-se a vazão natural afluente como a que representa toda a água que aflui a uma usina, e a vazão incremental afluente que representa a água que aflui a esta usina descontando-se a água proveniente de usinas de montante.

Usinas hidroelétricas podem ainda ser classificadas como:

- *usinas de reservatório*: possuem reservatórios com grande capacidade de regularização capazes de estocar água, chamados reservatórios de acumulação. Elas permitem variações no volume do reservatório e, conseqüentemente, na altura de queda.
- *usinas a fio d'água*: possuem reservatórios com pouca capacidade de regularização, também chamados de reservatórios de compensação. Nesse tipo de usina não é permitido variações de volume, então toda a vazão afluente que chega nelas é turbinada.

3.2 Geração Termelétrica

A geração termelétrica baseia-se na queima de combustíveis fósseis como carvão, gás, óleo, ou ainda a energia da fissão nuclear. Ela é a forma mais antiga de geração de energia elétrica e geralmente possui grande aceitação em países com pouco potencial hidráulico e países com bastante disponibilidade de combustíveis fósseis. Se comparado com as hidrelétricas, as usinas termelétricas possuem um baixo custo de implantação, porém devido à necessidade de combustível, além de ser uma fonte poluente, possuem maior custo de operação. Outra vantagem das termelétricas é a sua versatilidade devido ao tamanho reduzido, a sua simplicidade de operação, da rapidez na tomada e redução de carga, além de possuir maior flexibilidade quanto ao local geográfico de instalação, sendo largamente empregado em regiões remotas onde não há rede de distribuição, e também como fonte redundante para garantir alta disponibilidade de energia em repartições públicas, hospitais, e empresas. No Brasil, no ano de 2015, a oferta interna de energia elétrica oriunda de geração térmica correspondeu a 30,5% do total (EPE 2016).

O processo de geração nas usinas termelétricas, baseia-se na transformação de energia térmica em energia mecânica, que movimenta uma turbina acoplada a um gerador.

Tais usinas são classificadas quanto ao tipo de combustível utilizado e a forma como ele é queimado, podendo ser divididas em dois grupos: usinas convencionais, cujos combustíveis são fósseis, como carvão, óleo, gás natural e biomassa; e usinas nucleares, que utilizam combustíveis físséis, como o urânio natural e enriquecido.

A forma como esses combustíveis são queimados dividem as usinas termelétricas em usinas a vapor, a gás, ou à combustão direta. Nas usinas a vapor a queima do combustível aquece uma caldeira cheia d'água, que por sua vez produz vapor. Sob pressão, o vapor faz girar as pás da turbina, gerando energia cinética de rotação das pás, que por final é transformada em energia elétrica por meio de um gerador. Em usinas a gás, as pás das turbinas entram em movimento devido a pressão de uma mistura gasosa de ar comprimido e gás resultante da queima de combustíveis. Já as usinas de combustão direta, utiliza-se motores que trabalham de forma semelhante ao que acontece com os motores de automóveis, ou seja, existem pistões alimentados por um combustível fóssil. Esses motores de combustão direta são acoplados a geradores elétricos, que transformam a energia mecânica em elétrica.

A geração de energia em uma usina termelétrica está associada à aquisição do combustível primário, existindo uma relação produção custo para cada unidade geradora. Somado aos custos dos combustíveis, estão os custos operacionais, como mão-de-obra e manutenção de equipamentos. Contudo, como não há métodos diretos para expressar tais custos em função da saída, geralmente esses custos operacionais são considerados como custos fixos. O custo total costuma ser modelado como uma função convexa e crescente, aproximada por polinômios de segundo ou terceiro grau (El-Hawary 1979), com limites de geração mínima e máxima.

3.3 O Planejamento da Operação Energética

O planejamento da operação energética de sistemas hidrotérmicos visa minimizar os custos de operação. Sabendo que geração termelétrica funciona em regime complementar à geração hidrelétrica, e que tem um custo de geração superior, é necessário determinar o melhor despacho hidrelétrico em um determinado período de tempo de forma a minimizar a necessidade de queima de combustível para a produção de energia elétrica, e consequentemente minimizando o custo total de geração.

A formulação matemática do problema considera as vazões afluentes e a demanda conhecidos, levando em conta as características individuais das unidades geradoras. Nesta abordagem, a representação do parque termelétrico é simplificada por uma única usina fictícia, não sendo explicitada a distribuição de geração entre as usinas do parque, o que pode ser resolvido através da execução de um despacho econômico termelétrico (DET). Adotando-se uma discretização mensal, a função objetivo a ser atendida é a apresentada a seguir pela equação 3.10:

$$\min F = \sum_{t=1}^T [f(gt_t)] \quad (3.10)$$

onde:

- F - é o custo térmico total durante o horizonte (dado em \$);
- T - é o número de estágios do horizonte de planejamento (intervalo de tempo - em meses);
- t - é o índice do intervalo de tempo (mês);
- gt_t - é a geração termelétrica durante o intervalo t (dado em MW1);
- f - é a função de custo de geração térmica no instante t (dado em \$);

Por convenção, a curva de custo de combustível na geração em usinas térmicas é representado por segmentos de funções quadráticas da potência produzida nos geradores. Logo, o custo de operação termelétrica pode ser aproximado por um polinômio de segundo grau conforme a equação 3.11.

$$f(gt_t) = \alpha + \beta * gt_t + \gamma * gt_t^2 \quad (3.11)$$

onde α ; β ; γ são os coeficientes da função custo de geração térmica.

A função objetivo a ser minimizada está sujeita às seguintes restrições:

- balanceamento de carga no sistema - a demanda de energia elétrica deve ser atendida pela geração hidrelétrica e pela complementação dada pela geração termelétrica, conforme a equação 3.12:

$$gt_t + \sum_{i=1}^N gh_{it} - D_t - L_t = 0 \quad (3.12)$$

onde D_t representa a demanda no período t (MW), L_t representa as perdas na transmissão de energia no instante t (MW), gh_{it} é a geração da usina hidrelétrica i durante o intervalo t , i é o índice da usina hidrelétrica no sistema e N é o número de usinas hidrelétricas do sistema;

- geração hidrelétrica de energia - a geração de energia elétrica pelas usinas é uma função do volume armazenado e das vazões turbinada e vertida, conforme a equação 3.13:

$$gh_{it} = k_i * [h_{mon}(v_{it}) - h_{jus}(q_{it} + spl_{it}) - pc] * q_{it} \quad (3.13)$$

onde gh_{it} é a geração da usina hidrelétrica i durante o intervalo t , K_i a produtividade da usina i , $h_{mon}(v_{it})$ a função da cota de montante do reservatório da usina i no instante $t(m)$, $h_{jus}(q_{it} + spl_{it})$ a função da cota de jusante do reservatório da usina i no instante $t(m)$, q_{it} a vazão turbinada pela usina i durante o intervalo $t(m^3/s)$, spl_{it} a vazão vertida pela usina i durante o intervalo $t(m^3/s)$ e pc as perdas hidráulicas na geração daquela usina (que nesses estudo foram desprezadas);

- balanceamento dinâmico de água - o volume do reservatório de uma usina num determinado instante t é o volume que ela possuía no instante anterior, somado ao que ela recebeu de água, e subtraído o que ela devolveu de água ao sistema conforma a equação 3.14:

$$v_{it} = v_{i,t-1} + y_{it} - q_{it} - spl_{it} + \sum_{m=1}^{\phi_i} (q_{m,t} + spl_{m,t}), m \in \phi_i, \quad (3.14)$$

onde v_{it} é o volume do reservatório da usina i no final do intervalo $t(hm^3)$, $v_{i,t-1}$ é o volume do reservatório da usina i no instante anterior a t , ou seja, $t - 1(hm^3)$, y_{it} é a razão incremental afluenta à usina i durante o intervalo $t(m^3/s)$, q_{it} a vazão turbinada pela usina i durante o intervalo t , spl_{it} é a vazão vertida pela usina i durante o intervalo t e ϕ_i é o conjunto das usinas imediatamente a montante da usina i ;

- limites de geração de energia térmica - a geração de energia térmica está sujeita às restrições físicas da própria usina, logo, possui uma faixa de geração mínima e máxima, conforme a equação 3.15:

$$gt^{min} \leq gt_t \leq gt^{max} \quad (3.15)$$

onde gt^{min} e gt^{max} são as capacidades mínima e máxima de geração térmica, respectivamente, enquanto gt_t é a geração termelétrica durante o intervalo t ;

- limites de geração de energia hidráulica - a geração de energia hidráulica está sujeita às restrições físicas da própria usina, possuindo um faixa de geração mínima e máxima, conforme a equação 3.16:

$$gh_i^{min} \leq gh_{it} \leq gh_i^{max} \quad (3.16)$$

onde gh_i^{min} e gh_i^{max} representam as capacidades mínima e máxima de geração hidráulica da usina i , respectivamente, e gh_{it} a geração da usina hidrelétrica i durante o intervalo t ;

- limites de armazenamento de reservatórios - os limites de volumes de uma usina devem ser respeitados, de maneira que a água excedente deve ser vertida, e o volume não deve ficar abaixo do volume mínimo de operação, conforme equação 3.17:

$$v_i^{min} \leq v_{it} \leq v_i^{max} \quad (3.17)$$

onde v_i^{min} e v_i^{max} são o volume mínimo e máximo do reservatório da usina i , e v_{it} é o volume do reservatório da usina i no final do intervalo t ;

- volume inicial de operação - para iniciar o estudo, deve ser atribuído um estado inicial de volume para cada uma das usinas, conforme a equação 3.18:

$$v_{i0} = v_i^{inicial} \quad (3.18)$$

onde $v_i^{inicial}$ representa o volume inicial do reservatório da usina i ;

- volume final desejado de operação - para garantir um estado final de operação viável, a otimização deve atender um critério de volume final, conforme descreve a equação 3.19:

$$v_{iT} = v_i^{final} \quad (3.19)$$

onde v_i^{final} é o volume final do reservatório da usina i desejado ao final da otimização;

- limites de turbinagem - a vazão turbinada pelas usinas hidráulicas estão sujeitas às restrições físicas das mesmas, sendo que essa turbinagem deverá respeitar um limite máximo e mínimo, conforme a equação 3.20:

$$q_i^{min} \leq q_{it} \leq q_i^{max}(h_i(t)) \quad (3.20)$$

onde q_i^{min} e $q_i^{max}(h_i(t))$ são as turbinagens mínima e máxima da usina i , e $h_i(t)$ a altura de queda da usina i no intervalo t .

4 O Ambiente Computacional de Simulação e Otimização

O modelo proposto por esse trabalho consiste na aplicação de algoritmos meta-heurísticos baseados em enxame de partículas para a resolução do problema de planejamento energético de sistemas hidrotérmicos. Para a sua efetiva execução foi necessário a implementação de uma aplicação composta por duas ferramentas independentes: um simulador de usinas hidrelétricas individualizadas com regras de políticas operacionais e um otimizador meta-heurístico. Ambas são descritos a seguir:

- Simulador Web de Usinas Hidrelétricas: trata-se de um software para simulação de usinas hidrelétricas do Sistema Interligado Nacional dentro de um período estabelecido, aplicando políticas operacionais sobre o comportamento da simulação. Essas políticas operacionais representam as metas que o simulador deverá atender, assim, uma política operacional do tipo *Turbinagem* tentará atender os valores de turbinagem definidos pelos valores de metas de turbinagem de cada usina em cada período, respeitando os limites operativos de cada usina.

O simulador foi inteiramente desenvolvido na linguagem de programação Java (Oracle 2016) fazendo uso das características dessa linguagem, especialmente a adoção do princípio de Programação Orientada a Objeto. Nele foi implementado toda a modelagem matemática para o funcionamento das usinas hidrelétricas e das usinas térmicas, incluindo todas as restrições operativas.

Uma das principais características do mesmo é a possibilidade de se fazer uso da tecnologia de Webservice para sua operação, o que garante ao sistema a independência e a interoperabilidade com softwares externos. Por meio dessa tecnologia um sistema externo pode fazer uma solicitação de simulação através de uma chamada ao simulador, durante a chamada será necessário a transferência de um arquivo XML contendo todos os parâmetros e demais dados necessários para a execução da simulação desejada. Por sua vez, ao final do processamento, o sistema responde com um arquivo XML contendo os dados detalhados do resultado daquela simulação.

- Otimizador de Usinas Hidrelétricas: O otimizador foi desenvolvido com o objetivo de otimizar a geração de energia elétrica para um grupo de usinas hidrelétricas do Sistema Interligado Nacional. O processo de otimização visa a realização de estudos com parâmetros predefinidos, objetivando proporcionar resultados padronizados de forma que seja possível fazer uma comparação consistente dos resultados obtidos por algoritmos diferentes.

Este otimizador faz uso do framework JMetal ([Nebro 2016](#)) que é composto por um conjunto de algoritmos e problemas independentes. Como o framework é de livre domínio, é possível acessar todo o seu código fonte, fazer modificações, criar novos algoritmos ou ainda implementar novos problemas. Para a execução desse trabalho, foram implementados os algoritmos, *AbeePSO*, *LSSPSO*, e *KFPSO*, todos derivados da classe *Problem* original do JMetal.

4.1 Algoritmos

Os algoritmos utilizados no estudo do problema em questão, foram os algoritmos de Otimização por Enxame de Partículas (*Particle Swarm Optimization - PSO*) e suas variantes. O PSO tem sido aplicado em uma grande variedade de problemas e muitas vezes tem obtido bons resultados. Trata-se de uma técnica de otimização heurística baseada no comportamento social, onde a busca nesse algoritmo se dá pelas informações trocadas entre indivíduos, chamados partículas, e a população chamada enxame.

Dentre as variantes do *PSO* implementadas e avaliadas neste estudo estão: *LSSPSO*, *ABeePSO* e *KFPSO*. Ambos os algoritmos foram implementados sobre a plataforma do JMetal, fazendo reutilização do código do framework e desenvolvendo classes que herdam de outras classes originais do JMetal. Todos esses algoritmos são apresentados nos capítulos [5](#), [6](#), [7](#) e [8](#).

5 Algoritmo Particle Swarm Optimization

O algoritmo *Particle Swarm Optimization (PSO)* é bastante utilizado para a resolução de problemas não lineares e contínuos. Sua simplicidade de implementação, a pouca necessidade de parametrização, e sua grande facilidade de modificação e adaptação para lhe incorporar novas características que permitirão melhor explorar outros comportamentos, além do bom desempenho em funções de teste em vários estudos, tem atraído bastante atenção, apesar de não oferecer garantia de convergência para um solução global.

O PSO foi originalmente proposto por (Kennedy e Eberhart 1995), e compreende uma técnica estocástica baseada no comportamento social, mais especificamente inspirado no comportamento de bandos de pássaros e cardumes. Nele um conjunto de partículas, que juntas formam um enxame, trocam informações entre si e se ajudam mutuamente em busca um bom resultado para o problema a ser tratado. As partículas do enxame, que representam possíveis soluções do problema, exploram o espaço de busca multidimensional ajustando suas trajetórias, a cada iteração, a partir de um fator inercial, e considerando a melhor posição já assumida por cada partícula individualmente e também a melhor posição adquirida pelo enxame.

Em algumas variantes do algoritmo original, um grupo de partículas é dividido em mais de um enxame, fazendo com que as partículas troquem informações apenas com aquelas que são membros do mesmo enxame, e que os enxames troquem informações entre si com uma frequência menor. Conforme será explorado, cada variante visa tirar proveito de alguma propriedade do algoritmo, enquanto outras tentam acrescentar mais características ou até corrigir algumas deficiências, como a dificuldade do algoritmo de explorar bem o espaço de busca quando encontra pontos ótimos locais.

Conforme apresentado em 1, o algoritmo inicia-se com a definição de posições aleatórias $\vec{X}_i$ para cada partícula no espaço de busca, representando uma possível solução do problema, além de uma velocidade inicial $\vec{V}_i$, também aleatória. As variáveis são representadas por vetores multidimensionais que se adaptam à dimensão do problema a ser tratado. A cada iteração, as partículas sobrevoam o espaço de busca do problema procurando uma melhor solução, segundo sua velocidade atual $\vec{V}_i$, a melhor posição encontrada pela partícula ($\vec{P}_{Best_i}$) e a melhor posição encontrada pelo enxame até o momento ($\vec{G}_{Best_i}$).

A posição e velocidade das partículas são atualizadas a cada iteração usando os valores de $\vec{P}_{Best_i}$ e $\vec{G}_{Best_i}$, conforme as equações:

$$\begin{aligned} \vec{V}_{id}(t+1) &= \omega * \vec{V}_{id}(t) + \\ &C_1 * rand[0, 1] * [\vec{P}_{Best_i}(t) - \vec{X}_{id}(t)] + \\ &C_2 * rand[0, 1] * [\vec{G}_{Best_i}(t) - \vec{X}_{id}(t)] \end{aligned} \quad (5.1)$$

$$\vec{X}_{id}(t+1) = \vec{X}_{id}(t) + \vec{V}_{id}(t+1) \quad (5.2)$$

para: $i = 1, \dots, N_p$ $d = 1, \dots, N_g$ onde:

- N_p : É o número de partículas do bando.
- N_g : É o número de variáveis de decisão (dimensões) de uma partícula.
- t : É o índice da iteração.
- ω : É o fator de inércia.
- $C1$ e $C2$: são constantes de aceleração que ponderam a influência das posições $\vec{P}_{Best_i}$ e $\vec{G}_{Best_i}$ sobre as partículas, respectivamente.
- $rand[0, 1]$: É um valor aleatório uniformemente distribuído no intervalo $[0, 1]$.
- $\vec{V}_i(t)$: É a velocidade da partícula i na iteração t .
- $\vec{X}_i(t)$: É a posição atual da partícula i na iteração t .

Algoritmo 1: Pseudo-código do algoritmo PSO.

Criar população inicial;

Avaliar população inicial segundo a função objetivo;

Inicializar a velocidade de busca de cada partícula;

Inicializar o ponto ótimo local de cada partícula, com os mesmos dados iniciais da partícula;

Determinar o ponto ótimo global de todo o enxame;

while *Iteração* < *Número máximo de iterações* **do**

Computar a velocidade de cada partícula;

Computar a nova posição de cada partícula;

Avaliar toda a população segundo a função objetivo;

Atualizar o ponto ótimo local de cada partícula;

Atualizar o ponto ótimo global de todo o enxame;

end

As constantes $C1$ e $C2$ definem a aceleração das partículas, e ponderam a influência das posições $\vec{P}_{Best_i}$ e $\vec{G}_{Best_i}$ sobre as partículas, respectivamente (K. Basu M. 2008). Essas constantes são também conhecidas como coeficientes de fator cognitivo (influência da

melhor posição da própria partícula) e social (influência da melhor posição de todo o conjunto). Os desenvolvedores do algoritmo PSO (Kennedy e Eberhart 1995) sugerem a utilização de valores próxima a 2, de forma que quando multiplicadas a valores randômicos variando de 0 a 1, em média as constantes tendem a apresentar um valor prático próximo de 1. Grandes valores para essas constantes fazem com que as partículas saltem boas soluções, enquanto pequenos valores fazem com que a partícula dificilmente mude sua direção, impedindo o algoritmo de convergir.

A velocidade máxima permitida para uma partícula é definida por V_d^{max} , caso esse valor seja muito grande, as partículas podem acabar saltando boas soluções enquanto sobrevoam o espaço de busca, o que pode limitar o desempenho de convergência. Por outro lado, um valor muito pequeno de V_d^{max} dificulta que as partículas explorem de forma adequada todo o espaço de busca, ficando presas em soluções locais. Quando uma partícula extrapola o limite de velocidade V_d^{max} , o algoritmo corrige o valor desse variável para a partícula em questão, definindo a variável com o valor máximo V_d^{max} .

Alguns problemas podem apresentar uma limitação no tamanho do espaço de busca, ou podem apresentar restrições de forma que uma solução só pode ser factível se estiver dentro de certo limite do espaço de busca, dessa forma o algoritmo deve ser capaz de verificar a cada iteração e para cada partícula, durante o cálculo da posição seguinte, se essa nova posição não extrapola o campo de busca. Caso positivo, o algoritmo deve reposicionar a partícula na borda do espaço de busca, o mais próximo possível do ponto anteriormente calculado como sendo a nova posição da partícula.

Outra variável é encarregada de controlar o impacto das velocidades anteriores da partícula na velocidade atual. A variável ω é denominada *fator de inércia* e é encarregada de cumprir esse papel. Ela permite um balanço entre uma maior exploração global (cobrindo um área maior de exploração) ou local (exploração minuciosa em uma área). É comum decrementar esse fator no decorrer das iterações para permitir uma maior exploração global no início do algoritmo, e uma exploração mais refinada no final das iterações, segundo a equação 5.3.

$$\omega = \omega_{max} - \frac{\omega_{max} - \omega_{min}}{iter_{max}} * t \quad (5.3)$$

onde:

- ω_{max} : é o limite máximo para o fator de inércia.
- ω_{min} : é o limite mínimo para o fator de inércia.
- $iter_{max}$: é o número máximo de iterações.
- t : é a iteração atual.

6 Algoritmo Local Stochastic Search Particle Swarm Optimization

O algoritmo de otimização por enxame de partículas tem sido utilizado com sucesso para resolver muitos problemas do mundo real, porém este tem dificuldades em manter um balanceamento entre explorar rapidamente todo o espaço de busca e aproveitar toda a diversidade deste espaço, especialmente em ambientes dinâmicos.

Com o objetivo de melhorar a performance, (Ding Jin Liu 2014), introduziram a técnica de busca estocástica local ao PSO genérico, levando assim à criação de uma variante do algoritmo de otimização por enxame de partículas, o LSSPSO.

A abordagem proposta pelo LSSPSO é inspirada por um fenômeno social em que cada indivíduo deseja primeiro se destacar em seu ambiente de convívio mais próximo e posteriormente em toda a sociedade.

Mais especificamente, este algoritmo ajusta o fator de inércia para manter um balanceamento da velocidade de convergência, evitar que o algoritmo convirja muito rapidamente e permitir que ele explore melhor o espaço de busca. Assim, a diversidade do espaço é melhor explorada, permitindo o algoritmo a convergir satisfatoriamente e evitando que o enxame fique preso em pontos ótimos locais, introduzindo uma nova orientação de trajetória ao enxame.

Como mecanismo de funcionamento, supondo que o problema em tratamento seja de minimização, para cada partícula $\vec{X}_i(t)$ no enxame, uma nova partícula $\vec{X}_i(t+1)$ é gerada a partir das equações do algoritmo PSO genérico. Recombinando as partículas $\vec{X}_i(t)$ e $\vec{X}_i(t+1)$, uma terceira partícula $p\vec{X}_i(t+1)$ é gerada conforme a equação (4):

$$p\vec{X}_i(t+1) = \begin{cases} \vec{X}_i(t+1), & \text{Se } f(\vec{X}_i(t+1)) < f(\vec{X}_i(t)) \\ & e \quad rand(0,1) < pr; \\ \vec{X}_i(t), & \text{Caso contrario} \end{cases} \quad (6.1)$$

$$p\vec{V}_i(t+1) = \vec{V}_i(t+1) \quad (6.2)$$

para: $i = 1, 2, \dots, N$. onde:

- $f()$: É o resultado da função objetivo.
- $rand(0,1)$: É um número aleatório no intervalo $[0, 1]$.
- pr : É uma constante pré-definida em 0,5.

Após a seleção, uma segunda recombinação é utilizada como a seguir:

$$\begin{aligned} \vec{X}_i(t+1) &= \{p\vec{X}_i, \\ \text{Se } f(p\vec{X}_i(t+1)) &< f(\vec{X}_i(t)); \\ \text{e } \vec{X}_i(t), \text{ Caso Contrario. } \} \end{aligned} \quad (6.3)$$

No PSO genérico, as partículas tendem a se mover em uma mesma direção ao mesmo tempo em que se aproximam, assim, ao longo de várias iterações tendem a se tornarem similares. Neste algoritmo, quando a partícula temporária $p\vec{X}_i(t+1)$ é selecionada na próxima geração, as dissimilaridades entre $p\vec{X}_i(t+1)$ e $\vec{X}_i(t+1)$ irão determinar as dissimilaridades entre $\vec{X}_i(t+1)$ substituída por $p\vec{X}_i(t+1)$ e o resto das partículas do enxame. Uma maior dissimilaridade entre as partículas do enxame, representa uma maior diversidade de partículas, melhorando assim a capacidade do algoritmo de explorar o espaço de busca. Dessa forma o valor de pr controla a diversidade do enxame.

O LSSPSO introduz um novo mecanismo de busca estocástica local onde uma partícula tenta descobrir um ponto ótimo local em uma direção, e então continua se movendo nessa direção ao invés de procurar por outras direções ao ser influenciada por outras partículas. Assim, a velocidade de cada partícula passa a ser atualizada a cada iteração como a seguir:

$$\begin{aligned} \vec{V}_i(t+1) &= \{ \omega * rand(0, 1) * \vec{V}_i(t), \\ \text{Se } \vec{X}_i(t) &= \vec{G}_{Best}; \quad \text{e} \\ \omega * rand(0, 1) * \vec{V}_i(t) &+ r * randV, \text{ Caso contrario. } \} \end{aligned} \quad (6.4)$$

onde:

- r : É uma pequena constante.
- $randV$: É um vetor unitário aleatório.

Finalmente, $LSS\vec{X}_i(t+1)$ é atualizado para:

$$LSS\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{V}_i(t+1) \quad (6.5)$$

onde $LSS\vec{X}_i(t+1)$ é uma variável temporária, $LSS\vec{X}_i(t+1)$ é comparada com $\vec{X}_i(t+1)$. Se o valor da função objetivo de $LSS\vec{X}_i(t+1)$ for melhor que $\vec{X}_i(t+1)$, significa que, se

$LSS\vec{X}_i(t+1)$ superar $\vec{X}_i(t+1)$, a partícula i continuará a se mover na mesma direção.

Algoritmo 2: Pseudo-código do algoritmo LSSPSO.

Criar população inicial;

Avaliar população inicial segundo a função objetivo;

Inicializar a velocidade de busca de cada partícula;

Inicializar o ponto ótimo local de cada partícula, com os mesmos dados iniciais da partícula;

Determinar o ponto ótimo global de todo o enxame;

while *Iteração* < *Número máximo de iterações* **do**

 Salvar estado das partículas na iteração imediatamente anterior;

 Computar a velocidade de cada partícula;

 Computar a nova posição de cada partícula;

 Avaliar toda a população segundo a função objetivo;

 Aplicar mecanismo de melhoria da diversidade do enxame;

 Atualizar o ponto ótimo local de cada partícula;

 Atualizar o ponto ótimo global de todo o enxame;

end

7 Algoritmo Adaptative Bee and Particle Swarm Optimization

Assim como o LSSPSO, o ABeePSO tenta aprimorar o comportamento do algoritmo PSO genérico no sentido de explorar melhor o campo de busca multidimensional. Como já apresentado, o PSO original converge de forma muito rápida, o que o impede de explorar toda a diversidade do campo de busca, podendo levar que o enxame até mesmo fique preso em um ponto ótimo local.

O algoritmo Artificial Bee Colony – ABC – apresenta uma interessante capacidade de explorar a diversidade mesmo quando as partículas estão estagnadas em uma determinada região. Então ele pode ser mesclado ao PSO genérico para que o algoritmo explore a diversidade do espaço de busca ao mesmo tempo em que converge rapidamente.

O algoritmo Adaptative PSO, possui a capacidade de ajustar a velocidade de convergência dependendo unicamente do estado de diversidade do enxame. Este estado de diversidade é mesurado a partir de um fator conhecido como fator de diversidade, f_d , e calculado como em (9):

$$f_d = \frac{(d_g - d_{min})}{(d_{max} - d_{min})} \quad \epsilon [0, 1] \quad (7.1)$$

onde d_g é a distância média entre a melhor partícula do enxame e as demais partículas, d_{min} e d_{max} são a menor e a maior distância média entre todas as partículas, respectivamente. A partir do fator de diversidade, o enxame é classificado a partir de uma regra abstrata, em um dos seguintes estados: Convergência, Aproveitamento, Exploração, Salto.

Assim, ([Bastos-Filho L. N. Vitorino 2015](#)), mesclou o APSO ao algoritmo ABC formando o algoritmo Adaptative Bee PSO – ABeePSO – que tenta tirar proveito das propriedades de cada um deles.

O ABeePSO utiliza o mecanismo de exploração do algoritmo ABC apenas quando o enxame atinge o estado de convergência. Neste ponto, o enxame é dividido em dois grupos, para um enxame de N partículas, as $\frac{N}{2}$ partículas com os melhores resultados formarão o grupo das partículas guias, e serão aquelas que explorarão o campo de busca por elas mesmas, as outras $\frac{N}{2}$ partículas será as partículas guiadas, e explorarão o espaço de busca com base em informações passadas pelas partículas guias.

A velocidade de cada partícula guia será atualizada conforme a equação (10):

$$\vec{V}_i = \vec{X}_i + \vec{S} * \vec{R}_i * [\vec{X}_i - \frac{(\vec{B})}{Dist(\vec{B} - \vec{X}_i)}] \quad (7.2)$$

onde $\vec{B}$ é o baricentro do grupo das partículas guias, $\vec{R}_i$ é o vetor dos números aleatórios

gerados por uma distribuição uniforme no intervalo de $[0, 1]$, e $Dist()$ é a distância Euclidiana entre o baricentro ($\vec{B}$) e a atual posição da partícula ($\vec{X}_i$), e ($\vec{S}$) é um vetor que define o passo de dispersão do enxame.

Para as partículas guiadas, a velocidade será atualizada conforme a equação (11)

$$\vec{V}_i = \vec{X}_i + \vec{R}_i \{f\vec{S}_i - \vec{B}\} \quad (7.3)$$

onde $\vec{R}_i$ é um vetor de números aleatórios gerado por uma distribuição uniforme no intervalo de $[0, 1]$, e $f\vec{S}_i$ é um ponto de potencial solução para o problema de otimização selecionado pela partícula guiada.

O algoritmo finaliza a execução do mecanismo de exploração do algoritmo ABC, apenas quando o estado de diversidade do enxame passa de Convergência para Salto, ou para Exploração. Então o algoritmo prossegue o mecanismo de exploração do Adaptative PSO.

Algoritmo 3: Pseudo-código do algoritmo ABeePSO

Criar população inicial;

Avaliar população inicial segundo a função objetivo;

Inicializar a velocidade de busca de cada partícula;

Inicializar o ponto ótimo local de cada partícula, com os mesmos dados iniciais da partícula;

Determinar o ponto ótimo global de todo o enxame;

while *Iteração* < *Número máximo de iterações* **do**

 Computar a velocidade de cada partícula;

 Computar a nova posição de cada partícula;

 Avaliar toda a população segundo a função objetivo;

 Atualizar o ponto ótimo local de cada partícula;

 Atualizar o ponto ótimo global de todo o enxame;

 Computar a distância média entre as partículas;

 Definir o estado do enxame;

 Aplicar a estratégia da colônia artificial de abelhas;

end

8 Algoritmo Kalman Filter Particle Swarm Optimization

O filtro de Kalman é um tipo de método para a realização de estimativas com sucessivos cálculos que envolve a análise de grandes distorções ao longo do tempo. A proposta do algoritmo *Kalman Filter-based Particle Swarm Optimization* Otimização de Partícula com Filtro de Kalman (Wu et al. 2016), é utilizar o filtro de Kalman para estimar a nova posição de cada partícula a cada iteração. Essa predição é combinada com o mecanismo de aprendizagem do algoritmo PSO genérico, de forma que é escolhida para a próxima iteração a posição que apresenta um melhor resultado segundo a função objetivo. Essa técnica deve incrementar a diversidade da população do enxame, pode evitar que o enxame caia em pontos ótimos locais, e deve incrementar a capacidade do algoritmo em convergir reduzindo o número de iterações necessárias para alcançar uma solução ótima sem prejudicar a qualidade da solução final.

Segundo a proposta apresentada, para se determinar a próxima posição da partícula é necessário a posição atual $\vec{X}_i(t)$ e a melhor posição já encontrada por essa partícula $\vec{P}_{Best}(t)$, então a posição seguinte é determinada segundo as equações 8.1, 8.2 e 8.3:

$$\vec{X}_i(t+1) = F * \vec{X}_i(t) + \vec{K}(t) * (\vec{P}_{Best}(t) - H * F * \vec{X}_i(t)) \quad (8.1)$$

$$K(t+1) = (F * N(t) * F^T + Q) * H^T * (H * (F * N(t) * F^T + Q) * H^T + R)^{-1} \quad (8.2)$$

$$N(t) = (I - K(t))(F * N(t) * F^T + Q) \quad (8.3)$$

onde $F = H = I =$ matriz identidade; $Q = 0,0001$; $R = 0,1 * \text{diag}(V(t))$; $\text{diag}(V(t))$ é a matriz diagonal de $V(t)$; $N(0)$ é uma matriz unitária; $V(t)$ é a velocidade da partícula.

Assim que a nova posição $\vec{X}_i(t+1)$ é determinada, um filtro é aplicado a partir da seguinte distribuição:

$$\vec{X}_i(t+1) = \text{Normal}(F * \vec{X}_i(t+1), N(t)) \quad (8.4)$$

Algoritmo 4: Pseudo-código do algoritmo KFPSO

```
Criar população inicial;
Avaliar população inicial segundo a função objetivo;
Inicializar a velocidade de busca de cada partícula;
Inicializar o ponto ótimo local de cada partícula, com os mesmos dados iniciais da
partícula;
Determinar o ponto ótimo global de todo o enxame;
while Iteração < Número máximo de iterações do
    Computar a velocidade de cada partícula;
    Computar a nova posição de cada partícula de acordo com o filtro de Kalman;
    Computar a nova posição de cada partícula de acordo com o PSO;
    Selecionar as partículas de melhores posições entre as partículas calculadas com o
    filtro de Kalman e com o PSO;
    Avaliar toda a população segundo a função objetivo;
    Atualizar o ponto ótimo local de cada partícula;
    Atualizar o ponto ótimo global de todo o enxame;
end
```

9 Estudos de Caso

Os algoritmos PSO, ABeePSO, LSSPSO e KFPSO foram executados no ambiente de simulação escrito no capítulo 4 e terão seus resultados apresentados, analisados e comparados no capítulo em questão. Além da comparação entre si, serão comparados também com o algoritmo Programação Não Linear (PNL) (Marques 2006).

Durante a configuração do processo de execução dos algoritmos mencionados, dois objetivos foram selecionados, são eles:

- Redução do custo de geração: Compreende, para cada período, a soma do valor da complementação da geração térmica à geração hidrelétrica, ou seja, o cálculo observa o valor de complementação térmica necessária para a geração máxima no período, conforme representado na fórmula 9.1:

$$\sum [(\sum geracao_{usina}^{máxima} - \sum_{período} geracao_{usina})^2] / 2 \quad (9.1)$$

- Maximização da energia armazenada: Compreende a energia potencial armazenada no reservatório da usina ao final de cada período. Para o cálculo é utilizado o valor de turbinagem de todo o volume de água armazenado ao final de cada período, conforme a equação 9.2, explicada em 3.8.

$$p(x.u) = k.(h_{mon}(x) - h_{jus}(u) - pc).q \quad (9.2)$$

9.1 Cenário dos Estudos de caso

Foi utilizado um conjunto de 8 usinas hidrelétricas reais para o estudo. Os valores de Potência Instalada dessas usinas são descritos na tabela 3 com o respectivo valor da potência instalada.

Para a realização dos estudos foram utilizados dados de um período considerado crítico por apresentar um baixo valor de vazão natural dos rios, o que torna esse período um bom cenário para aferir a qualidade dos algoritmos, esse período é compreendido entre 01/05/1951 e 30/04/1956, totalizando 60 meses. Para cada estudo foi realizado uma série de 10 estudos com 100 partículas em 1000 iterações cada - a média dos resultados de cada algoritmo em cada método de Sorteio e com cada taxa de penalidade é apresentado nas próximas Seções.

Usina	Potência Instalada (MW)
Furnas	1312,00
Mascarenhas de Moraes	478,00
Marimbondo	1488,00
Água Vermelha	1396,20
Emborcação	1192,00
Itumbiara	2082,00
São Simão	1710,00
Ilha Solteira	3444,00

Tabela 3 – Usinas hidrelétricas utilizadas para realização dos experimentos

9.1.1 PSO

9.1.1.1 Sorteio Normal

Algoritmo	Custo	Energia Armazenada(%)
PNL	1,48e+09	100
PSO 10e00	2,28E+09	55
PSO 10e08	2,36E+09	50
PSO 10e18	2,18E+09	32
Média PSO	2,27E+09	46

Tabela 4 – Resultados com o Algoritmo PSO e sorteio normal

9.1.1.2 Sorteio Spline

Algoritmo	Custo	Energia Armazenada(%)
PNL	1,48e+09	100
PSO 10e00	2.45E+09	65
PSO 10e08	2.51E+09	65
PSO 10e18	2.59E+09	71
Média PSO	2.52E+09	67

Tabela 5 – Resultados com o Algoritmo PSO e sorteio spline

Figura 6 – Gráfico Algoritmo PSO com sorteio normal

Figura 7 – Gráfico Algoritmo PSO com sorteio spline

Observa-se que em média o algoritmo PSO descrito no capítulo 5 apresenta um resultado final de 46% da capacidade de energia armazenada para sorteios normais e com um custo médio de 2,27e09, e um resultado final de 67% da capacidade de energia armazenada e custo médio de 2,52e09 para sorteios spline. Resultados aquém daqueles

apresentados pelo algoritmo PNL que consegue apresentar resultados com custo de 1,48e09 e 100% da capacidade de energia armazenada para ambos os sorteios.

9.1.2 LSSPSO

9.1.2.1 Sorteio Normal

Algoritmo	Custo	Energia Armazenada(%)
PNL	1,48e+09	100
LSSPSO 10e00	2,29E+09	57
LSSPSO 10e08	3,83E+09	100
LSSPSO 10e18	3,83E+09	100
Média LSSPSO	3,32E+09	86

Tabela 6 – Resultados com o Algoritmo LSSPSO e sorteio normal

9.1.2.2 Sorteio Spline

Algoritmo	Custo	Energia Armazenada(%)
PNL	1,48e+09	100
LSSPSO 10e00	2,19E+09	53
LSSPSO 10e08	3,74E+09	100
LSSPSO 10e18	3,44E+09	92
Média LSSPSO	3,12E+09	82

Tabela 7 – Resultados com o Algoritmo LSSPSO e sorteio spline

Figura 8 – Gráfico Algoritmo LSSPSO com sorteio normal

Figura 9 – Gráfico Algoritmo LSSPSO com sorteio spline

Observa-se que em média o algoritmo LSSPSO descrito no capítulo 6 apresenta um resultado final de 86% da capacidade de energia armazenada para sorteios normais e com um custo médio de 3,32e09, e um resultado final de 82% da capacidade de energia armazenada e custo médio de 3,12e09 para sorteios spline. Assim como o algoritmo PSO, o LSSPSO apresentou resultados aquém daqueles apresentados pelo algoritmo PNL que consegue apresentar resultados com custo de 1,48e09 e 100% da capacidade de energia armazenada para ambos os sorteios.

9.1.3 ABeePSO

9.1.3.1 Sorteio Normal

Algoritmo	Custo	Energia Armazenada(%)
PNL	1,48e+09	100
ABeePSO 10e00	2,13E+09	35
ABeePSO 10e08	2,32E+09	64
ABeePSO 10e18	2,34E+09	34
Média ABeePSO	2,27E+09	44

Tabela 8 – Resultados com o Algoritmo ABeePSO e sorteio normal

9.1.3.2 Sorteio Spline

Algoritmo	Custo	Energia Armazenada(%)
PNL	1,48e+09	100
ABeePSO 10e00	2,40E+09	59
ABeePSO 10e08	2,52E+09	64
ABeePSO 10e18	2,53E+09	59
Média ABeePSO	2,48E+09	61

Tabela 9 – Resultados com o Algoritmo ABeePSO e sorteio spline

Figura 10 – Gráfico Algoritmo ABeePSO com sorteio normal

Figura 11 – Gráfico Algoritmo ABeePSO com sorteio spline

Observa-se que em média o algoritmo ABeePSO descrito no capítulo 7 apresenta um resultado final de 44% da capacidade de energia armazenada para sorteios normais e com um custo médio de 2,27e09, e um resultado final de 61% da capacidade de energia armazenada e custo médio de 2,48e09 para sorteios spline. Assim como o algoritmo PSO, o ABeePSO apresentou resultados aquém daqueles apresentados pelo algoritmo PNL que consegue apresentar resultados com custo de 1,48e09 e 100% da capacidade de energia armazenada para ambos os sorteios.

9.1.4 KFPSO

9.1.4.1 Sorteio Normal

9.1.4.2 Sorteio Spline

Algoritmo	Custo	Energia Armazenada(%)
NPL	1,48e+09	100
KFPSO 10e00	2,51e+09	81
KFPSO 10e08	3,67e+09	91
KFPSO 10e18	3,78e+09	100
KFPSO Médio	3,32e+09	92

Tabela 10 – Resultados com o Algoritmo KFPSO e sorteio spline

Figura 12 – Gráfico Algoritmo KFPSO com sorteio spline

De forma semelhante, o algoritmo KFPSO descrito no capítulo 8 apresenta um resultado final médio de 92% da capacidade de energia armazenada para sorteios spline e com um custo médio de $3,32e09$, também aquém dos resultados apresentados pelo algoritmo PNL. Os resultados para sorteios normais não foram obtidos devido à inviabilidade computacional de ser obter resultados em um período razoável de tempo, visto que o KFPSO apresentou um comportamento que demandou várias ordens de tempo a mais que os demais algoritmos para executar um única iteração.

10 Conclusões

Este trabalho consiste na implementação e avaliação de algoritmos meta-heurísticos baseados em Enxame de Partículas para que possam ser executados juntamente com o simulador de usinas na tentativa de encontrar boas soluções para o problema de otimização de sistemas hidrotérmicos de geração. Conforme apresentado, o problema é de grande porte e envolve variáveis estocásticas, por tanto um problema complexo, onde a disposição das usinas em cascata adiciona dificuldades a mais, uma vez que decisões tomadas para uma usina a montante irá influenciar as demais usinas a jusante.

Cada algoritmo variante do PSO original, conforme apresentado nos capítulos 5, 6, 7 e 8, adotou um mecanismo diferente para agregar novos comportamentos ou adicionar mecanismos de aprimoramento ao PSO original. Algumas características como a dificuldade de se explorar de forma eficiente todo o espaço de busca, evitando uma convergência prematura, ou ainda evitar que o enxame fique preso a pontos ótimos locais, foram as motivações principais para a adição desses novos comportamentos, tentando assim conseguir um algoritmo ainda mais eficiente.

Como parâmetro para comparação da eficácia do processo de otimização os resultados de um otimizador de Programação Não Linear (PNL) desenvolvido por (Marques 2006) foi utilizado. Tendo como objetivo obter resultados equivalentes ou melhores a esse algoritmo iniciou-se uma etapa mais longa de ajustes dos parâmetros nos diversos algoritmos utilizados. Foram realizados estudos com populações que variavam em quantidade entre 50 a 1000 partículas, com variações de parâmetros específicos de cada algoritmo e estudos com iterações que variavam entre 100 a 10000, números considerados suficientes para que os algoritmos pudessem convergir e encontrar soluções razoáveis para o problema proposto.

O experimentos executados evidenciaram os resultados apresentados no capítulo 9, em que os algoritmos baseados em Enxame de Partículas conseguiram obter um valor de Energia Armazenada Final igual ao PNL, porém não obteve um custo de geração equivalente ou inferior a esse algoritmo.

10.1 Trabalhos Futuros

Os seguintes trabalhos futuros podem ser acrescentados à pesquisa:

1. Estudos de novos algoritmos para uso no otimizador, conforme estrutura do *JMetal*;
2. Estudos com algoritmos multiobjetivos, relacionando o uso consultivo da água por exemplo.

10.2 Publicações

Os dados gerados nesse trabalho originou a publicação no XXIII SIMPEP (Simpósio de Engenharia de Produção).

Referências

- Bastos-Filho L. N. Vitorino 2015 BASTOS-FILHO L. N. VITORINO, S. F. R. C. A. A mechanism based on artificial bee colony to generate diversity in particle swarm optimization. v. 148, p. 39 – 45, 2015. Citado na página 37.
- CEPEL 2016 CEPEL. *Centro de Pesquisas de Energia Elétrica*. 2016. Acessado 22-Fevereiro-2016. Disponível em: <<http://www.aneel.gov.br>>. Citado na página 18.
- Cicogna e Soares 1999 CICOGNA, M. A.; SOARES, S. Modelo de planejamento da operação energética de sistemas hidrotérmicos a usinas individualizadas orientado por objetos. *Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e Computação*, 1999. Citado na página 21.
- DECOMP 2016 DECOMP. *DECOMP*. 2016. Acessado 22-Fevereiro-2015. Disponível em: <<http://www.cepel.br/main.jsp?lumPageId=21CF888C4A1692FF014A784FD2AE60D0&lumS=cepelinternet.produto&CodProduto=4028B88136E3DBC70136E40CFBB32190&lumItemId=4028B88136E3DBC70136E40CFBC92192>>. Citado na página 19.
- DESSEM 2016 DESSEM. *DESSEM*. 2016. Acessado 22-Fevereiro-2015. Disponível em: <<http://www.cepel.br/main.jsp?lumPageId=21CF888C4A1692FF014A784FD2AE60D0&lumS=cepelinternet.produto&CodProduto=4028B88136E3DBC70136E40CFD5521C9&lumItemId=4028B88136E3DBC70136E40CFD6B21CB>>. Citado na página 19.
- Ding Jin Liu 2014 DING JIN LIU, K. R. C. W. Z. Q. H. J. L. J. A particle swarm optimization using local stochastic search and enhancing diversity for continuous optimization. v. 137, p. 261 – 267, 2014. Citado na página 34.
- El-Hawary 1979 EL-HAWARY, G. S. C. M. E. Optimal economic operation of electric power systems. *New York: Academic Press*, 1979. Citado na página 25.
- Energia 2016 ENERGIA, M. de Minas e. Resenha energética brasileira: Exercício 2015. 2016. Acessado 12-Setembro-2016. Disponível em: <[http://www.mme.gov.br/documents/10584/3580498/02+-+Resenha+Ener%C3%A9tica+Brasileira+2016+-+Ano+Base+2015+\(PDF\)/66e011ce-f34b-419e-adf1-8a3853c95fd4;jsessionid=B415252F7145EC1BD6596B2C8137D1B8.srv155?version=1.0](http://www.mme.gov.br/documents/10584/3580498/02+-+Resenha+Ener%C3%A9tica+Brasileira+2016+-+Ano+Base+2015+(PDF)/66e011ce-f34b-419e-adf1-8a3853c95fd4;jsessionid=B415252F7145EC1BD6596B2C8137D1B8.srv155?version=1.0)>. Citado 3 vezes nas páginas 7, 14 e 15.
- EPE 2016 EPE. Balanço energético nacional 2016: Ano base 2015. *Rio de Janeiro: EPE*, 2016. Acessado 12-Setembro-2016. Disponível em: <https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2016.pdf>. Citado 6 vezes nas páginas 7, 8, 12, 13, 14 e 24.
- K. Basu M. 2008 K. BASU M., C. N. M. K. Particle swarm optimization technique based short-term hydrothermal scheduling. *Applied Soft Computing*, v. 8, p. 1392–1399, 2008. Disponível em: <<http://dl.acm.org/citation.cfm?id=1410470.1410623>>. Citado na página 32.

- Kennedy e Eberhart 1995 KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: *Neural Networks, 1995. Proceedings., IEEE International Conference on*. [S.l.: s.n.], 1995. v. 4, p. 1942 –1948 vol.4. Citado 2 vezes nas páginas 31 e 33.
- Marques 2006 MARQUES, T. *Uma Política Operativa a Usinas Individualizadas para o Planejamento da Operação Energética do Sistema Interligado Nacional*. Tese (Doutorado) — Universidade Estadual de Campinas, 2006. Citado 4 vezes nas páginas 7, 21, 41 e 49.
- Nebro 2016 NEBRO, J. D. A. *Jmetal*. 2016. Acessado 14-Setembro-2016. Disponível em: <<http://jmetal.sourceforge.net/algorithms.html>>. Citado na página 30.
- NEWAVE 2016 NEWAVE. *NEWAVE*. 2016. Acessado 22-Fevereiro-2015. Disponível em: <<http://www.cepel.br/main.jsp?lumPageId=21CF888C4A1692FF014A784FD2AE60D0&lumS=cepelinternet.produto&CodProduto=4028B88136E3DBC70136E40CF79820E5&lumItemId=4028B88136E3DBC70136E40CF7AD20E7>>. Citado na página 18.
- NEWAVE 2013 NEWAVE, C.-P. Modelo estratégico de geração hidrotérmica a subsistemas equivalentes. *Manual do Usuário. Versão*, v. 12, 2013. Citado na página 18.
- Oracle 2016 ORACLE. *Java Developer Kit*. 2016. Acessado 12-Setembro-2016. Disponível em: <<http://www.oracle.com/technetwork/java/javase/documentation/index.html>>. Citado na página 29.
- PEREIRA 1985 PEREIRA, M. V. F. Optimal scheduling of hydrothermal systems – an overview. *Proc. IFAC Intl. Symposium on Planning and Operation of Electric Energy Systems*, 1985. Citado na página 17.
- Wu et al. 2016 WU, Y. et al. A self-adaptive chaos and kalman filter-based particle swarm optimization for economic dispatch problem. *Soft Computing*, Springer, p. 1–13, 2016. Citado na página 39.