

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

Ramon Abritta Aguiar Santos

Otimização da Produção de Energia Elétrica em Usinas Hidrelétricas

Juiz de Fora

2020

Ramon Abritta Aguiar Santos

Otimização da Produção de Energia Elétrica em Usinas Hidrelétricas

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica.

Orientador: Prof. Dr. Ivo Chaves da Silva Junior

Coorientador: Prof. Dr. André Luís Marques Marcato

Juiz de Fora

2020

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Santos, Ramon Abritta Aguiar.

Otimização da Produção de Energia Elétrica em Usinas Hidrelétricas /
Ramon Abritta Aguiar Santos. – 2020.

113 p. : il.

Orientador: Ivo Chaves da Silva Junior

Coorientador: André Luís Marques Marcato

Dissertação (mestrado acadêmico) – Universidade Federal de Juiz de
Fora, Faculdade de Engenharia Elétrica. Programa de Pós-graduação em
Engenharia Elétrica, 2020.

1. Inteligência Computacional. 2. Geração Hidrelétrica. 3. Gerencia-
mento de Recursos. 4. Otimização. 5. Planejamento da Operação. da Silva
Junior, Ivo Chaves, orient. II. Marcato, André Luís Marques, coorient. III.
Título.

Ramon Abritta Aguiar Santos

Otimização da Produção de Energia Elétrica em Usinas Hidrelétricas

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica.

Aprovada em 21 de Agosto de 2020

BANCA EXAMINADORA



Prof. Dr. Ivo Chaves da Silva Junior - Orientador
Universidade Federal de Juiz de Fora



Prof. Dr. André Luís Marques Marcato - Coorientador
Universidade Federal de Juiz de Fora



Prof. Dr. Edmarcio Antônio Belati
Universidade Federal do ABC



Prof. Dr. Bruno Henriques Dias
Universidade Federal de Juiz de Fora

AGRADECIMENTOS

Agradeço primeiramente a meu orientador, Dr. Ivo Chaves da Silva Junior, por ter me estendido a mão ainda na graduação quando pensei em sair do curso de Engenharia Elétrica, por ter me apresentado à área de otimização, na qual hoje tenho grande prazer de trabalhar, por ter me incentivado a entrar no mestrado e por ter me oferecido oportunidades que mudaram minha vida. A você, meu amigo, minha eterna gratidão.

Agradeço a meus pais, Luiz Carlos Martins dos Santos e Maria Aparecida Abritta de Aguiar Santos, por terem sido, em cada momento da minha vida, exatamente o que eu precisava que fossem. Agradecimento este que se estende aos meus irmãos, Luiz Carlos Martins dos Santos Filho e Samyra Abritta Aguiar Santos. Agradeço à minha família pelo incentivo constante, pela confiança, pela liberdade e pelo amor.

Agradeço a meus amigos, Felipe Rodrigues Mattos, Daniel Nocelli, Davi Lanzieri, Alan Guimarães, Rafael Garcia, Leiliane Oliveira, Áquila Boy, Caroline Philot, Deborah Franco, Walquíria Silva e Anapaula Guimarães, por esboçarem um sincero sorriso no rosto ao saberem de qualquer conquista minha e, aos que compartilharam salas de aula comigo, pela ajuda mútua e pelas horas de estudo. Desejo-lhes toda felicidade que for possível ter neste mundo.

Agradeço aos meus colegas de trabalho no mestrado, Dr. André Luís Marques Marcato, Dr. Leonardo de Mello Honório, Frederico Panoeiro e Pedro Nascimento, pelo profissionalismo e dedicação em realizar o melhor que pudéssemos. Agradeço em especial ao Dr. André Luís Marques Marcato pela orientação e suporte.

Finalmente, agradeço ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora (UFJF), à UFJF como um todo, ao Instituto Nacional de Energia Elétrica (INERGE), à companhia EDP e à Agência Nacional de Energia Elétrica (ANEEL), os quais, por meio do Programa de Pesquisa e Desenvolvimento, possibilitaram minha pesquisa, a qual está vinculada ao projeto sob código PD-00673-0052/2018.

RESUMO

Diante do cenário atual de maior preocupação com o desenvolvimento sustentável, fontes renováveis de energia têm se tornado cada vez mais importantes. Neste contexto, além de contribuírem com a maior parcela da geração renovável brasileira, usinas hidrelétricas são responsáveis pela maior parte da matriz energética em geral. Como diferentes estratégias de operação podem ser aplicadas a um conjunto de turbinas de uma usina para atender a mesma demanda de potência, este trabalho apresenta uma investigação de técnicas de inteligência computacional aplicadas à otimização da operação diária de usinas hidrelétricas. Tal estudo é motivado pelo potencial em se poupar recursos hídricos e financeiros, contribuindo assim para um melhor planejamento da operação do sistema elétrico, e também pela simplicidade de implementação e eficácia que técnicas de inteligência computacional têm apresentado ao longo dos anos. As seguintes contribuições são propostas: (i) uma aplicação até então não explorada na literatura envolvendo técnicas de inteligência computacional binárias, a qual, basicamente, se beneficia de algoritmos binários consolidados na literatura para solucionar problemas cujas variáveis de decisão são inteiras; (ii) uma adaptação de um modelo renomado de usinas hidrelétricas que viabiliza a economia máxima de recursos hídricos através de uma simples alteração na metodologia; e (iii) uma abordagem inovadora do ajuste de curvas de eficiência de turbinas hidráulicas, a qual almeja uma modelagem mais precisa de tal componente ao se aplicar técnicas baseadas no conceito de aprendizagem de máquinas. Simulações foram realizadas com dados de uma usina hidrelétrica pertencente ao grupo EDP. Adaptações dos algoritmos *Grey Wolf Optimizer* e *Sine Cosine Algorithm* e o algoritmo *Ant Colony Optimization* se mostraram altamente propícios a solucionar o problema em questão quando adequadamente configurados, visto que foram capazes de confiavelmente fornecer cronogramas de operação que correspondem a ótimos globais.

Palavras-chave: Inteligência Computacional. Geração Hidrelétrica. Gerenciamento de Recursos. Otimização. Planejamento da Operação.

ABSTRACT

Given the current scenario of greater concern regarding sustainable development, renewable energy sources have become increasingly important. Within this context, in addition to contributing to the greatest share of Brazilian renewable generation, hydroelectric power plants are responsible for most of the energy matrix in general. Since different operation strategies can be applied to a power plant's set of turbines to supply the same power demand, it is presented in this work an investigation of computational intelligence techniques applied to the optimization of the operation of hydroelectric power plants. Such a study is motivated by the potential to save hydro and financial resources, hence contributing to a better operation planning of the electric system, and also by the simplicity in implementation, and effectiveness that intelligent techniques have presented over the years. The following contributions are proposed: (i) an application not yet explored in the literature involving binary computational intelligence techniques, which, basically, benefits from binary algorithms consolidated in the literature to solve problems whose decision variables are integer; (ii) an adaptation of a well known hydroelectric power plants model which allows the maximum saving of hydro resources through a simple modification in the methodology; and (iii) an innovative approach to the fitting of hydraulic turbines efficiency curves, which aims for a more accurate modeling of this component by applying techniques based on the machine learning concept. Simulations were performed with data of a power plant belonging to the EDP group. Adaptations of the Grey Wolf Optimizer and Sine Cosine Algorithm, and the Ant Colony Optimization algorithm have shown to be highly propitious in solving the given problem when duly configured, given the fact that these were able to reliably providing operation schedules that correspond to global optimum.

Keywords: Computational Intelligence. Hydroelectric Generation. Resources Managing. Optimization. Operation Planning.

LISTA DE ABREVIATURAS E SIGLAS

ONS	Operador Nacional do Sistema
UHE	Usina hidrelétrica
ANEEL	Agência Nacional de Energia Elétrica
EDP	Energias de Portugal
TIC	Técnica de inteligência computacional
SCA	Sine Cosine Algorithm
GWO	Grey Wolf Optimizer
ACO	Ant Colony Optimization
FOB	Função objetivo
FCM	Fuzzy C-Means
CET	Curva de eficiência de turbinas
ANFIS	Adaptive network-based fuzzy inference system
ELM	Extreme learning machine
ELANFIS	Extreme learning adaptive network-based fuzzy inference system
VP	Valor de pertinência
SCA _{xr}	Sine Cosine Algorithm com arredondamento e equações originais
SCA _r	Sine Cosine Algorithm com arredondamento e equações modificadas
SCA _{xb}	Sine Cosine Algorithm binário com equações originais
SCA _b	Sine Cosine Algorithm binário com equações modificadas
GWO _r	Grey Wolf Optimizer com arredondamento
GWO _b	Grey Wolf Optimizer binário
CS1	Conjunto de simulações 1 - sem limites e com penalização
CS2	Conjunto de simulações 2 - com limites e sem penalização
DP	Desvio padrão
TA	Taxa de acerto
TMS	Tempo médio de simulação
u.a.	Unidade arbitrária

LISTA DE SÍMBOLOS

E_{PG}	Energia potencial gravitacional
m	Massa
g	Aceleração da gravidade
h_{qb}	Altura de queda bruta
P_{PG}	Potência potencial gravitacional
Δt	Intervalo de tempo
σ	Densidade da água turbinada
Vol	Volume de água turbinada
q	Vazão turbinada por uma unidade geradora
p_g	Potência gerada por uma unidade
η_{tur}	Eficiência da turbina
η_{ger}	Eficiência do gerador
h_{ql}	Altura de queda líquida
f_{per}	Função de perda de potência no gerador
X_i^z	Valor da dimensão i do indivíduo X na iteração z do SCA
P_i^z	Valor da dimensão i do melhor indivíduo P da iteração z do SCA
z_{max}	Número máximo de iterações
a	Coefficiente de exploração
α	Indivíduo mais apto no GWO
β	Segundo indivíduo mais apto no GWO
γ	Terceiro indivíduo mais apto no GWO
ω	Demais indivíduos no GWO
Sig	Função sigmoide
n_{bits}	Número máximo de <i>bits</i> em um indivíduo binário
\mathbb{Z}	Conjunto dos números inteiros
h_{ph}	Perdas hidráulicas na forma de altura
k_{ph}	Coefficiente de perdas hidráulicas
p_1	Perda de potência por fatores hidráulicos
p_2	Perda de potência por elevação do nível jusante
p_3	Perda de potência por queda de eficiência das turbinas
k_{ph}	Coefficiente de perdas hidráulicas
n_{ug}	Número de unidades geradoras em uma usina
q_{tot}	Vazão turbinada total
n	Número de unidades geradoras em operação
h_r	Nível montante (nível do reservatório)
h_j	Nível jusante
Q	Vazão defluente dada pelo turbinamento total acrescido do vertimento
p_m	Potência mecânica
$p_{g_{tot}}$	Potência gerada total
p_{min_n}	Geração mínima com n unidades

p_{max_n}	Geração máxima com n unidades
T	Número de períodos no horizonte de planejamento
c_{pp}	Custo de uma partida ou parada de máquina
c_{per}	Valor financeiro de 1 MWh
fun_n	Função de perdas de potência para n unidades
d_t	Meta de geração (demanda) no período t
$n_{t_{min}}$	Número mínimo de unidades que pode atender a demanda d_t
$n_{t_{max}}$	Número máximo de unidades que pode atender a demanda d_t
D_E	Distância Euclidiana
D_M	Distância de Mahalanobis
N_C	Número de clusters
e_{med}	Erro médio
e_{max}	Erro máximo

SUMÁRIO

1	INTRODUÇÃO	15
1.1	PROGRAMAÇÃO DIÁRIA E TRABALHOS RELACIONADOS	16
1.2	OBJETIVO E MOTIVAÇÃO	19
1.3	TRABALHOS PUBLICADOS	20
1.4	ORGANIZAÇÃO DA DISSERTAÇÃO	20
2	HIDROELETRICIDADE E OTIMIZAÇÃO INTELIGENTE .	21
2.1	SISTEMAS DE GERAÇÃO HIDRÁULICA	21
2.2	OTIMIZAÇÃO VIA INTELIGÊNCIA COMPUTACIONAL	24
2.2.1	Revisão Bibliográfica	25
2.2.2	Sine Cosine Algorithm	26
2.2.3	Grey Wolf Optimizer	30
2.2.4	Ant Colony Optimization	33
2.2.5	Modificação no Sine Cosine Algorithm	35
2.2.6	Adaptações em Técnicas de Inteligência Computacional	36
2.2.7	Otimização Discreta via Algoritmos Binários	37
3	MODELO DE USINA HIDRELÉTRICA	41
3.1	DESCRIÇÃO DO MODELO DE REFERÊNCIA	42
3.2	ANÁLISE E MODELAGEM DA CURVA COLINA	47
3.2.1	Banco de Dados da Curva Colina	48
3.2.2	Métodos de Ajuste	49
3.2.3	Resultados	51
4	ESTUDOS DE CASO	59
4.1	EXPANSÃO DO MODELO DE USINA HIDRELÉTRICA	59
4.2	SIMULAÇÕES	61
4.2.1	Dados de Entrada	62
4.2.2	Obtenção das Funções de Perdas e Vazões	63
4.2.3	Otimização da Operação	65
4.2.3.1	<i>Resultados com aplicação de penalizações</i>	69
4.2.3.2	<i>Resultados com aplicação de limites</i>	84
4.2.4	Análise de Sensibilidade	87
4.2.5	Resultados Hidrológicos e Operacionais	90
5	CONCLUSÕES	95
5.1	Trabalhos Futuros	95
	REFERÊNCIAS	97
	APÊNDICE A – Parâmetros de Modelagem da Curva Colina	105
	APÊNDICE B – Informações Estatísticas Adicionais	107
	ANEXO A – Direitos Autorais ACO Yarpiz	113

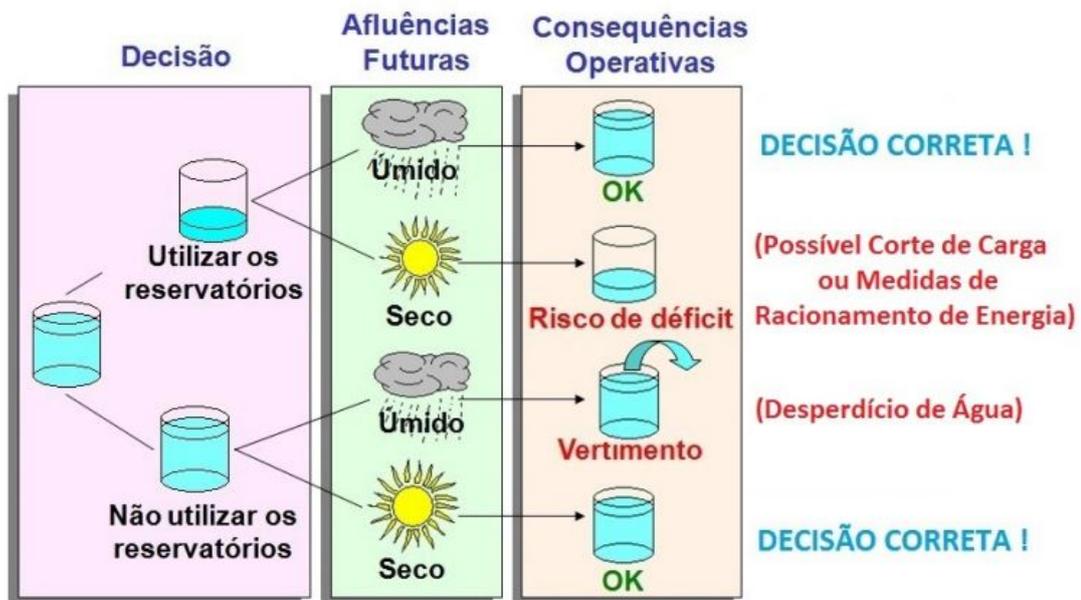
1 INTRODUÇÃO

Em um sistema elétrico predominantemente hidrotérmico, como o brasileiro, é necessário que as demandas energéticas sejam atendidas com segurança, confiabilidade e utilização mínima de usinas térmicas, dados os elevados custos associados à operação destas. Dentro deste contexto, deve-se visar o uso de recursos hídricos do modo mais eficiente possível.

Uma decisão presente de turbinar água dos reservatórios será pertinente se posteriormente houver precipitação pluviométrica, restabelecendo os níveis de armazenamento dos reservatórios, e não pertinente caso contrário, ocasionando assim falta de combustível para geração hidrelétrica e exigindo geração térmica. Por outro lado, uma decisão presente de poupar água do reservatório e, portanto, utilizar térmicas, será pertinente se posteriormente não houver precipitação pluviométrica, evitando assim a incapacidade de atender demandas, e não pertinente caso contrário, o que implica em gastos com a utilização das térmicas, as quais, no Brasil, são sempre complementares à geração hidrelétrica.

Embora as decisões não sejam tão diretas quanto apresentado no parágrafo anterior, este ilustra o cenário genérico de como atua o planejamento da operação. Percebe-se que se busca decisões ótimas em relação às escolhas presentes e as consequências futuras, o que essencialmente constitui o conhecido dilema do operador, ilustrado na Figura 1.

Figura 1 – Dilema do operador



Fonte: (1).

Um fator que eleva significativamente a complexidade de um sistema hidrotérmico é dado pela existência de usinas em cascata, isto é, usinas que estejam situadas em um

mesmo rio, resultando assim em um acoplamento temporal e espacial das decisões entre as mesmas. Se, por exemplo, a usina B está a jusante da usina A, a afluência no reservatório da usina B está fortemente ligada à defluência da usina A, exigindo assim uma operação coordenada.

No Brasil, o Operador Nacional do Sistema (ONS) divide o planejamento em longo, médio e curto prazo, ao passo que enquanto menor for o horizonte de planejamento, ou de programação, maior deve ser o nível de detalhamento do modelo. Estes planejamentos se dão, respectivamente, em horizontes de cinco anos com discretização mensal (2), de um mês com discretização semanal (3) e de um dia com discretização de meia em meia hora (4), sendo que cada um dos dois primeiros estabelece diretrizes para o seguinte.

Sobre o planejamento de curto prazo, ressalta-se que cada usina hidrelétrica (UHE) possui autonomia para definir como suas unidades geradoras serão operadas para que as metas de geração fornecidas pelo ONS sejam atendidas. Ou seja, existe potencial para economia de recursos e/ou redução de custos através de operações otimizadas. Tais otimizações são realizadas com uso de variadas técnicas, o que será exposto na seção a seguir.

Neste trabalho, fruto do projeto de P&D da ANEEL sob código PD-00673-0052/2018, os algoritmos de inteligência computacional *Ant Colony Optimization*, *Grey Wolf Optimizer* e *Sine Cosine Algorithm* foram implementados e analisados, visando assim um estudo em relação à potencialidade de se aplicar métodos “inteligentes” na otimização da operação diária de uma UHE do grupo EDP.

1.1 PROGRAMAÇÃO DIÁRIA E TRABALHOS RELACIONADOS

Com base em previsões de carga, em diretrizes oriundas dos planejamentos de curto prazo e em possíveis restrições operativas por parte das UHEs, o ONS provê cada usina com despacho centralizado ligada à sua rede de operação (5) com as metas de geração a serem atendidas ao longo do dia.

A dinâmica de produção energética em UHEs envolve uma série de complexidades devido à não linearidades. Por exemplo, apesar do aumento da vazão turbinada elevar a potência gerada, estas grandezas não são diretamente proporcionais, visto que o aumento da primeira também ocasiona uma elevação do nível jusante, o que reduz a altura de queda, que por sua vez reduz a geração. Além disso, alterações na vazão e na altura de queda implicam em variações no rendimento da turbina, o que será detalhado posteriormente. Portanto, determinar a operação ótima de UHEs não é uma tarefa trivial.

A otimização da operação diária visa atingir um certo objetivo operacional de acordo com as condições atuais da UHE. Em períodos de escassez pluviométrica, geralmente se busca a economia de recursos hídricos, visto que utilizar diferentes quantidades de

unidades geradoras para se atender uma mesma demanda (também denominada meta de geração) implica em diferentes consumos, assumindo, obviamente, que tal demanda esteja dentro do intervalo de geração associado a estas quantidades de unidades geradoras. Além disso, ainda que com uma mesma quantidade de unidades geradoras ligadas, a forma como se distribui a geração entre estas unidades possui influência no consumo hídrico. Por outro lado, em períodos com abundância de recursos hídricos, pode ser uma melhor opção operar a UHE de modo a minimizar ao máximo as ocorrências de partidas e paradas das unidades geradoras, mesmo que tal decisão implique em pontos operativos menos eficientes. Tal afirmação se justifica pelo fato de partidas e paradas contribuírem para a redução das vidas úteis das máquinas, o que se torna prioritário evitar em cenários nos quais o reservatório está cheio a ponto de acarretar vertimento. Obviamente, neste caso deve-se garantir que a geração ocorra dentro da zona de operação contínua.

Para atingir os objetivos mencionados no parágrafo anterior, várias formas de se definir o problema podem ser implementadas. Formulações presentes na literatura apresentam funções objetivo baseadas na minimização de vazões, minimização de custos operacionais, maximização da eficiência, entre outras. Os parágrafos a seguir se dedicam a expor alguns trabalhos, dispostos em ordem cronológica de publicação, relacionados à otimização da operação diária de UHEs. Notar-se-á que, ao decorrer dos anos, houve um aumento na tendência a se explorar técnicas baseadas em inteligência computacional na resolução do problema.

Pereira (6) minimiza o custo operacional de sistemas hidrelétricos em cascata com base no custo de gerações térmicas devido ao não atendimento da demanda exclusivamente via recursos hídricos. Vazões incrementais são implementadas de forma estocástica. A partir da linearização por partes aplicada na função objetivo, soluciona-se o problema ao se definir um algoritmo estocástico de decomposição em múltiplos estágios. Simulações realizadas com dados de sistemas brasileiros demonstraram a eficácia do método.

Piekutowski, Litwinowicz e Frowd (7) aplicam um modelo linearizado para sistemas hidrelétricos de grande porte e realizam a minimização de custos energéticos através de *softwares* comerciais de programação linear. A formulação modela conexões em corrente contínua para fins de exportação e importação energética entre Tasmânia e Austrália. Resultados indicaram uma economia energética anual de 0,3% a 0,4%.

Ponrajah, Witherspoon e Galiana (8) escrevem a formulação como uma minimização de vazões e a resolvem por técnicas baseadas em Relaxação Lagrangeana. Testes realizados em dois sistemas hidrelétricos localizados em Ontario, Estados Unidos, apontam um ganho de 0,25% de produção. O modelo leva em consideração despachos monitorados/otimizados em tempo real.

Nilsson, Soder e Sjelvgren (9) escrevem o problema com base em custos por comercialização de potência, no valor financeiro da água remanescente no reservatório ao

fim da programação e em custos oriundos de partidas e paradas de unidades geradoras, para então solucioná-lo via decomposição combinada à Relaxação Lagrangeana. É destacada a importância de se modelar a reserva girante analisando cada unidade geradora individualmente em vez de considerar a capacidade de toda a usina simultaneamente.

Breton, Hachem e Hammadia (10) formulam o problema como uma maximização da potência gerada diante de um valor disponível de vazão. A resolução é dada por Programação Dinâmica. Restrições relacionadas aos canais das usinas e à rede de transmissão são consideradas na formulação. Resultados mostraram que tais restrições não adicionaram esforço computacional no método de solução proposto. Além disso, indicaram que ganhos relevantes são obtidos ao se considerar tais restrições.

Ohishi et al. (11) comparam uma combinação de Algoritmos Genéticos com Relaxação Lagrangeana a uma decomposição baseada em Programação Dinâmica e Relaxação Lagrangeana aplicados à minimização do custo operacional diário de um sistema composto por dezesseis usinas. Com base em simulações realizados com dados históricos, ambas heurísticas mostraram ganhos significativos em comparação à operação de fato efetuada.

Bortoni, Bastos e Souza (12) propõem uma abordagem que não requer qualquer informação prévia sobre eficiências de componentes do sistema. Uma técnica heurística de otimização combinatória é desenvolvida para resolver o problema de maximização da eficiência global em tempo real. Testes mostraram benefícios em se otimizar a operação em tempo real mesmo diante de cronogramas planejados previamente.

Sousa, Jardini e Lima (13) escrevem a formulação como uma maximização da eficiência e a resolvem por técnicas Lagrangeanas. Um sistema de monitoramento é utilizado para mensurar valores de grandezas lidas por uma série de instrumentos. Resultados mostraram inconsistências nos valores lidos em campo, indicando assim a necessidade de revisar os modelos.

Chen et al. (14) minimizam o custo de produção de um sistema hidrotérmico via *Particle Swarm Optimization*. O método é testado em um sistema real contendo vinte e duas unidades térmicas e três UHEs em cachoeiras. Resultados mostraram que soluções de alta qualidade são consistentemente obtidas.

Fernandes et al. (15) formulam uma maximização da eficiência solucionada por Algoritmos Genéticos. O modelo parte da análise de curvas que descrevem a eficiência das máquinas em função de suas potências nominais e visa encontrar a combinação de curvas que maximiza a geração para determinados níveis de carga. Simulações foram realizadas com dados das UHEs Sobradinho e Ilha Solteira. Os resultados enfatizaram a importância de se escolher o modelo de curva de eficiências adequadamente.

Finardi, Takigawa e Brito (16) minimizam a defluência de UHEs via diferentes metodologias clássicas de otimização. Mais especificamente, comparam abordagens baseadas em Relaxação Lagrangeana, em um *solver* para problemas de programação não-linear inteira

mista e um algoritmo de programação linear inteira mista aplicado após a linearização do problema. Testes foram realizados em um sistema de oito UHEs em cascata contendo um total de vinte e nove unidades geradoras. Os resultados indicaram um desempenho superior por parte da Relaxação Lagrangeana.

Dal’Santo e Costa (17) calculam curvas de perdas de potência para cada possibilidade de número de unidades geradoras em operação. A existência de grupos com unidades geradoras que apresentam características distintas entre si é considerada e o *solver* DICOPT é utilizado para realizar a otimização. Os autores defendem que o método proposto garante o menor uso possível dos recursos hídricos.

Ming et al. (18) utilizam o algoritmo *Cuckoo Search* para determinar o número de unidades geradoras que devem operar em cada período, enquanto que o despacho é determinado via programação dual. Como o modelo incorpora restrições relacionadas à gerações fotovoltaicas, as quais são de difícil previsão, uma abordagem estocástica é aplicada. Um método para redução de dimensionalidade de acordo com restrições de *minimum uptime* e *minimum downtime* é apresentado. Simulações com dados retirados de históricos operacionais mostraram uma economia de água do reservatório em comparação às operações efetuadas.

Brito, Finardi e Takigawa (19) expõem e analisam os erros de quatro distintas possibilidades de aproximação da função de produção hídrica, isto é, da curva que define a geração em função dos demais parâmetros. Além disso, sete modelos lineares por partes são otimizados pelo *solver* Gurobi e comparados em relação à qualidade de resultados e ao esforço computacional.

1.2 OBJETIVO E MOTIVAÇÃO

Almeja-se neste trabalho realizar um estudo aprofundado de técnicas de inteligência computacional de otimização aplicadas ao problema de otimização da operação diária de UHEs, sendo o alvo de estudo uma usina real pertencente ao grupo EDP. Isto é, deseja-se avaliar como tais técnicas em suas formas originais e modificadas desempenham diante do problema em questão. Mais especificamente, objetiva-se aplicar algoritmos de inteligência computacional binários no problema discreto em questão, adaptar o modelo de UHEs de modo a proporcionar maior economia de recursos hídricos e propor uma modelagem mais precisa da curva de eficiência das turbinas hidráulicas.

Em relação ao problema tratado, a motivação é oriunda das possibilidades de economizar recursos hídricos e poupar equipamentos via planejamentos operacionais otimizados. A operação ótima de UHEs colabora para que se obtenha um cenário mais sustentável a longo prazo, tanto em relação à disponibilidade de combustível para geração, quanto à minimização de acionamentos de máquinas térmicas, as quais estão associadas a altos custos operativos. Em relação às metodologias de solução, ou seja, às aplicações das

técnicas de inteligência computacional, a motivação vem de se testar se algoritmos que mostraram excelente desempenho em diversas áreas de pesquisa são capazes de solucionar o problema estudado em um tempo viável e com alta confiabilidade.

1.3 TRABALHOS PUBLICADOS

A seguir são dispostos os trabalhos publicados oriundos da pesquisa aqui descrita:

- Abritta, Ramon; Panoeiro, Frederico F.; de Aguiar, Eduardo P.; Honório, Leonardo de M.; Marcato, André L. M.; da Silva Junior, Ivo C. Fuzzy system applied to a hydraulic turbine efficiency curve fitting. *Electrical Engineering*. 2020.
- Abritta, Ramon; Panoeiro, Frederico F.; da Silva Junior, Ivo C.; Marcato, André Luís Marques; de Mello Honório, Leonardo; de Oliveira, Luiz Eduardo. Turbines Allocation Optimization in Hydro Plants via Computational Intelligence In: *Advances in Intelligent Systems and Computing*. 1 ed.: Springer International Publishing, 2020, v.1037, p. 314-329.
- Abritta, Ramon; Panoeiro, Frederico F.; da Silva Junior, Ivo C.; Marcato, André Luís Marques; de Mello Honório, Leonardo. Simple Algorithm for Maximum Water Saving at Hydroelectric Power Plants. Apresentado no congresso Clagtee 2019.

1.4 ORGANIZAÇÃO DA DISSERTAÇÃO

No Capítulo 2, explica-se brevemente a composição de usinas de geração hidrelétrica e como é dada a produção de energia em tais usinas. São apresentadas renomadas técnicas de inteligência computacional, sendo que aprofundamentos são realizados em relação às avaliadas neste trabalho. Além disso, modificações e possibilidades de adaptações em tais técnicas são expostas.

No Capítulo 3, o modelo escolhido para otimização da UHE estudada é exposto e justificado com base nas características da usina. Apresenta-se uma abordagem para ajuste de curvas de eficiência de turbinas hidráulicas alternativa ao ajuste polinomial, a qual se baseia no sistema Fuzzy e em redes neurais artificiais.

No Capítulo 4, as metodologias apresentadas são aplicadas aos dados da UHE estudada e uma série de resultados são analisados e discutidos visando a averiguação do quanto tais métodos são eficazes na resolução do problema estudado.

No Capítulo 5, expõe-se as conclusões deste trabalho e as possibilidades de continuidade em pesquisas futuras.

2 HIDROELETRICIDADE E OTIMIZAÇÃO INTELIGENTE

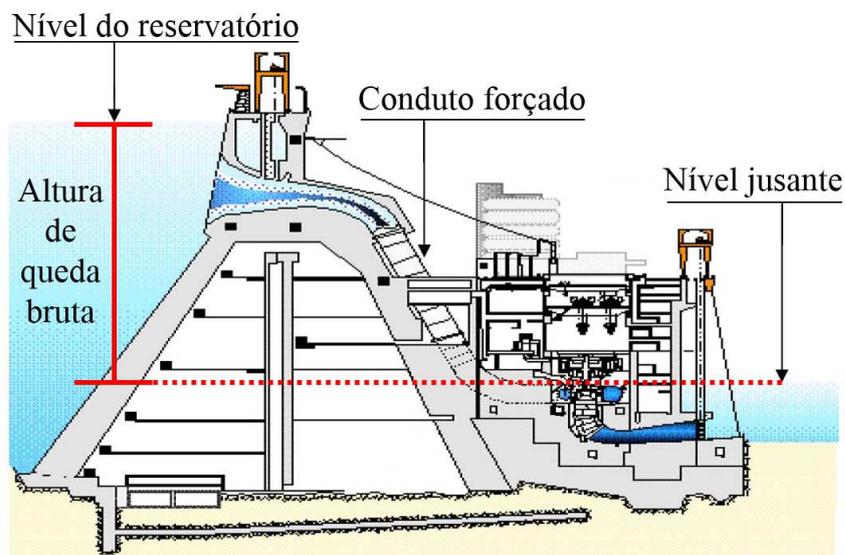
Este capítulo apresenta uma contextualização sucinta dos sistemas geradores de potência que utilizam turbinas hidráulicas para transformação da energia mecânica em elétrica. São abordados os pontos essenciais e suficientes para entendimento do trabalho desenvolvido. Além disso, é realizada uma revisão de técnicas de inteligência computacional – com foco maior nas aplicadas no estudo aqui apresentado – e são apresentadas modificações aplicadas em tais técnicas visando melhorias de desempenho e adaptabilidade para problemas de diferentes naturezas.

2.1 SISTEMAS DE GERAÇÃO HIDRÁULICA

Resumidamente, uma UHE é composta pela barragem, condutos forçados, casa(s) de força e vertedouro, sendo estes responsáveis por, respectivamente, formar o reservatório, levar água até as máquinas, alojar de forma segura os conjuntos turbina-gerador, isto é, as unidades geradoras, e descarregar, a jusante, excessos de água do reservatório. Algumas UHEs possuem, além dos vertedouros em formas de comportas comandadas pela equipe de operação, um vertedouro chamado Soleira Livre, o qual atua de forma independente quando o reservatório atinge um determinado nível (20).

Em sistemas de geração hidrelétrica, a energia potencial gravitacional (E_{PG}) da água é convertida em energia mecânica pela turbina. Esta energia é então transmitida por um eixo ao gerador, o qual finalmente a converte em energia elétrica. A dinâmica de produção de potência das unidades geradoras pode ser visualizada na Figura 2 e é calculada segundo os seguintes itens:

Figura 2 – Esquema genérico de uma UHE



Fonte: (21) (adaptada).

- A E_{PG} em joules é calculada de modo generalizado via Equação 2.1, em que m , g e h_{qb} são, respectivamente, a massa em quilogramas, a aceleração da gravidade em metros por segundo ao quadrado e a altura em metros, sendo que, no caso de UHEs, m se refere à massa da água turbinada e h_{qb} , denominada altura de queda bruta, é dada pela diferença entre o nível do reservatório (também conhecido como nível montante) e o nível a jusante, conforme ilustrado na Figura 2;

$$E_{PG} = m.g.h_{qb} \quad (2.1)$$

- Tendo em consideração o interesse em se calcular potência em vez de energia, pode-se reescrever a Equação 2.1 conforme Equação 2.2, em que se define uma potência potencial gravitacional (P_{PG}) a partir da definição de que a potência é dada pela razão entre a energia e o intervalo de tempo (Δt). A constante 10^{-6} na Equação 2.2 transforma a unidade de W para MW;

$$P_{PG} = 10^{-6}.m.g.h_{qb}/\Delta t \quad (2.2)$$

- Como a massa é dada pela multiplicação da densidade (σ) pelo volume (Vol), reescreve-se a Equação 2.2 conforme Equação 2.3, sendo que, no caso de UHEs, σ e Vol se referem à densidade e ao volume, respectivamente, de água turbinada;

$$P_{PG} = 10^{-6}.\sigma.Vol.g.h_{qb}/\Delta t \quad (2.3)$$

- Finalmente, com base na definição de que a vazão (q) é dada pela razão entre Vol e Δt , reescreve-se a Equação 2.3 conforme Equação 2.4, sendo que, no caso de UHEs, q se refere à vazão turbinada.

$$P_{PG} = 10^{-6}.g.\sigma.h_{qb}.q \quad (2.4)$$

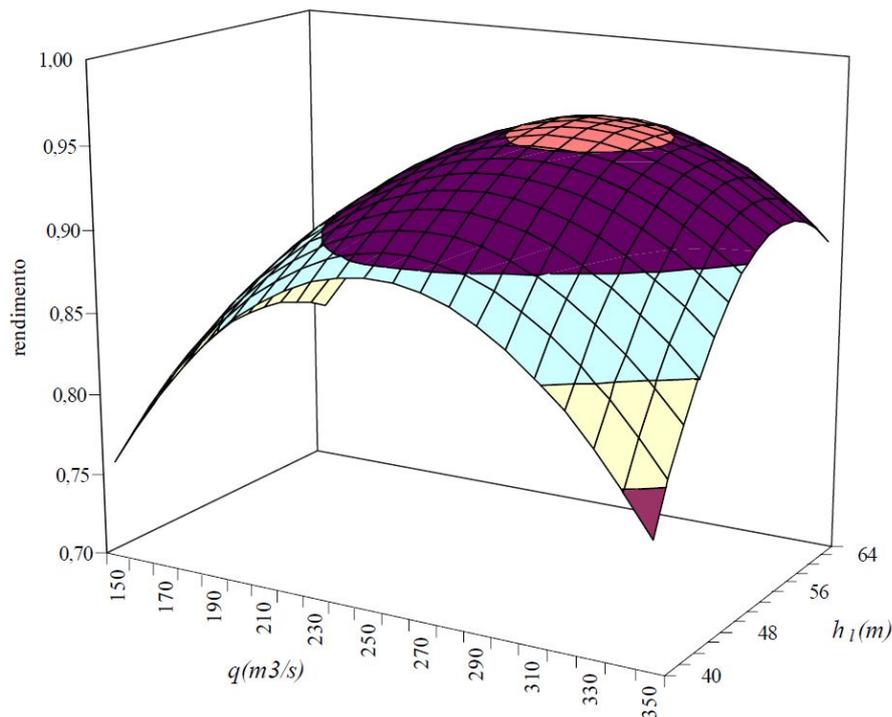
Em uma situação ideal, ou seja, sem perdas, a potência gerada (p_g) por uma unidade geradora seria dada pela Equação 2.4. No entanto, existem perdas de potência nas turbinas, nos geradores e no condutos forçados, com as últimas sendo oriundas do atrito entre a água e o conduto. Estas perdas, as quais serão discutidas mais detalhadamente posteriormente, impõem alterações na Equação 2.4 no sentido de se levar em consideração as eficiências da turbina (η_{tur}) e do gerador (η_{ger}). Recorda-se que, em qualquer sistema, pode-se definir a eficiência como a razão entre a potência de saída e a potência de entrada, ou seja, contabiliza-se assim as perdas associadas ao sistema. Também devem ser consideradas as perdas devido ao atrito, as quais são comumente modeladas na literatura como um coeficiente de perdas na forma de altura (h_{ph}) a ser subtraído de h_{qb} , dando origem à altura de queda líquida (h_{ql}). A potência gerada por uma unidade geradora é então dada de forma definitiva pela Equação 2.5.

$$p_g = 10^{-6}.g.\sigma.\eta_{tur}.\eta_{ger}.h_{ql}.q \quad (2.5)$$

Os níveis do reservatório (h_r) e jusante (h_j) são comumente dados por polinômios não lineares denominados, respectivamente, polinômio cota-volume, o qual fornece h_r em função do volume de água no reservatório, e polinômio vazão - nível jusante, o qual fornece h_j em função da vazão defluente da usina, a qual é dada pela soma da vazão turbinada pelas unidades geradoras com a vazão vertida. Existem também os polinômios denominados Cota-Área, os quais fornecem a área da superfície do reservatório em função do nível do mesmo. Sua utilização está relacionada a fenômenos de evaporação (22), o qual é um aspecto não abordado neste trabalho.

O rendimento de uma turbina hidráulica é representado por uma função não linear da vazão turbinada e da altura de queda líquida. Esta função é definida com base em uma curva de eficiência fornecida pelo fabricante da turbina, também conhecida como Curva Colina, como a exemplificada na Figura 3. As perdas nas turbinas se devem basicamente ao fato de parte da energia potencial da água se dissipar em perdas internas e externas na própria turbina (23).

Figura 3 – Curva Colina típica de uma turbina hidráulica



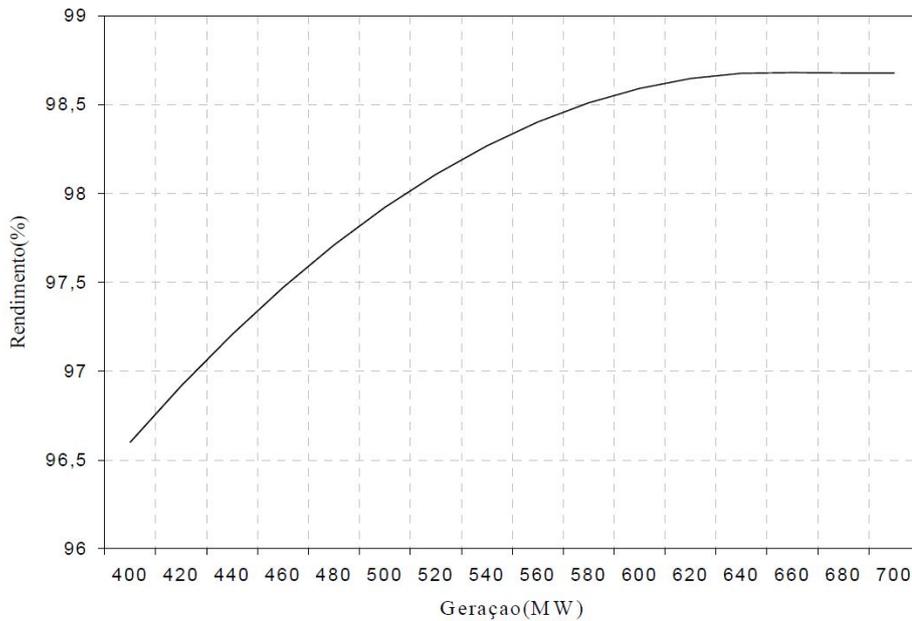
Fonte: (21).

A eficiência do gerador pode ser modelada como uma função da potência gerada, conforme (21; 23) e exemplificada na Figura 4. No entanto, também é possível modelar uma função (f_{per}) que forneça as perdas em função da geração, como adotado em (24), o que acarretaria na aplicação da Equação 2.6 para cálculo da potência gerada. As perdas em geradores se devem às resistências dos enrolamentos, atrito nas escovas, mancais,

sistemas de ventilação, histerese e correntes de Foucault, sendo modeladas a partir de ensaios realizados nas máquinas (25). Neste trabalho, será adotada a primeira alternativa.

$$p_g = 10^{-6} \cdot g \cdot \sigma \cdot \eta_{tur} \cdot h_{ql} \cdot q - f_{per}(p_g) \quad (2.6)$$

Figura 4 – Curva de eficiência dos geradores da UHE Itaipu Binacional



Fonte: (21).

2.2 OTIMIZAÇÃO VIA INTELIGÊNCIA COMPUTACIONAL

Técnicas de Inteligência Computacional (TICs), também conhecidas como meta-heurísticas, visam replicar aspectos de comportamentos inteligentes com o objetivo de solucionar problemas de grande complexidade. Como discutido em (26), TICs são comumente inspiradas em conceitos evolucionários, como em (27; 28), comportamentos de animais, como em (29; 30), ou fenômenos físicos, como em (31; 32). A popularidade destas técnicas tem crescido ao longo dos anos devido à simplicidade de implementação, flexibilidade de suas aplicabilidades, não dependência de derivadas e tendência à não estagnação em ótimos locais devido à natureza probabilística das mesmas.

A simplicidade destas técnicas permitem que novos algoritmos sejam desenvolvidos, melhorias sejam executadas, hibridizações sejam efetuadas e técnicas difundidas, como o elitismo e a mutação, sejam incorporadas. A flexibilidade diz respeito à estrutura do algoritmo como um todo, a qual requer pequenos ou até mesmo nenhum ajuste ao ser aplicado a um problema.

Muitos destes algoritmos utilizam um conjunto inicial de indivíduos (soluções candidatas) aleatórios que percorrem a região de solução e que se movem para áreas

promissoras ao compartilhar informações entre si sobre cada avaliação da função objetivo, ou seja, sobre suas aptidões. Idealmente, uma TIC é capaz de eficientemente explorar a região de solução visando encontrar áreas viáveis propícias e então intensificar a busca nestas áreas de modo a atingir a convergência.

Assim como em qualquer método probabilístico, em geral não é possível garantir a obtenção da solução ótima global ao se utilizar uma TIC em um problema de otimização. No entanto, com uma quantidade adequada de soluções candidatas e número de iterações, assumindo-se que adote-se o número máximo de iterações como critério de parada, aumenta-se a probabilidade de encontrar a solução ótima global ou uma solução sub-ótima. Ao aumentar estes parâmetros deve-se atentar, no entanto, para o quanto de esforço computacional será exigido.

2.2.1 Revisão Bibliográfica

Entre os Algoritmos Evolucionários, o mais difundido e popular é certamente o Algoritmo Genético (AG), o qual foi proposto em (27) e simula a Teoria da Evolução de Darwin. De modo geral, Algoritmos Evolucionários são baseados na melhoria de uma solução inicial através de mutações e combinações de indivíduos ao longo das gerações (iterações). Alguns algoritmos nesta categoria são: *Evolution Strategy* (ES) (33; 34), *Genetic Programming* (GP) (35), *Differential Evolution* (DE) (28), *Evolutionary Programming* (EP) (36; 37) e *Biogeography-based Optimization* (BBO) (38).

Outro ramo de TICs é o de Algoritmos Baseados na Física. Neste ramo de algoritmos, a atualização de posição das soluções candidatas ao longo das iterações é baseada em fenômenos físicos relacionados, por exemplo, às forças gravitacional e eletromagnética e à inércia. Entre os mais populares estão: *Gravitational Local Search Algorithm* (GLSA) (39), *Big-Bang Big-Crunch* (BBBC) (40), *Central Force Optimization* (CFO) (41), *Gravitational Search Algorithm* (GSA) (31), *Artificial Chemical Reaction Optimization Algorithm* (ACROA) (42), *Galaxy-based Search Algorithm* (GbSA) (43) e *Black Hole* (BH) (32).

O terceiro ramo principal de TICs é o de algoritmos baseados em Inteligência de Exame, o que essencialmente se relaciona a comportamentos animais. Estes algoritmos visam imitar o comportamento dos mais distintos grupos de animais presentes na natureza. Entre os algoritmos baseados em Inteligência de Exame que possuem vasta aplicação na literatura, estão: *Particle Swarm Optimization* (PSO) (29), *Artificial Bee Colony* (ABC) (44), *Ant Colony Optimization Algorithm* (ACO) (30), *Bat-Inspired Algorithm* (BA) (45), *Fruit Fly Optimization Algorithm* (FOA) (46), *Grey Wolf Optimizer* (GWO) (26) e *Whale Optimization Algorithm* (WOA) (47). Alguns outros algoritmos pertencentes a este grupo são: *Artificial Fish Swarm Algorithm* (AFSA) (48), *Monkey Search* (MS) (49), *Cuckoo Search* (CS) (50) e *Firefly Algorithm* (FFA) (51).

Neste trabalho, aplica-se o *Sine Cosine Algorithm* (SCA) (61), o qual não é classificado como pertencente a nenhum dos ramos mencionados, o GWO e o ACO na otimização da operação diária da UHE estudada. Aplicações recentes e bem sucedidas destas TICs incluem:

- SCA: otimização de parâmetro no método Support Vector Regression (52), previsão de velocidades do vento (53) e cálculo de fluxo de potência ótimo (54);
- GWO: treinamento de redes Perceptron (55), otimização multi-objetivo (56) e otimização de despachos térmicos (57);
- ACO: otimização em tempo de real de um sistema de gerenciamento de energia em microrrede autônoma (58), seleção em tempo real de rotas de trens (59) e atribuição ótima de portões em aeroportos (60).

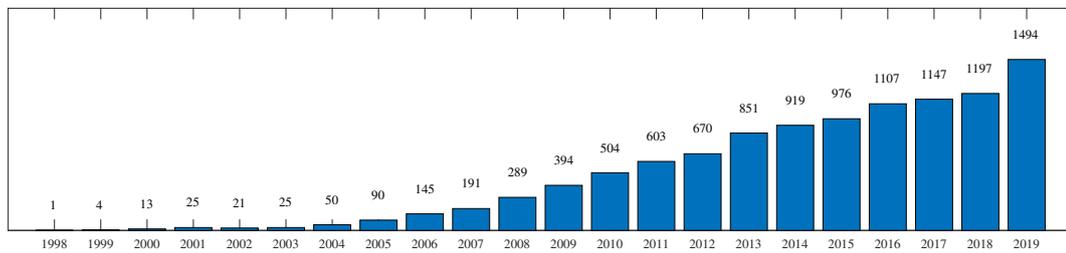
As escolhas pelo SCA e GWO se devem basicamente ao fato de serem técnicas que rapidamente demonstraram sucesso em diversas áreas de pesquisa. A escolha pelo ACO também está ligada ao seu grande sucesso em variadas aplicações, porém, além disso, esta TIC possui a distinta característica de realizar a busca de forma discreta, ou seja, neste algoritmo as variáveis de decisão possuem valores inteiros, ao contrário do SCA e do GWO, os quais buscam soluções em regiões contínuas. Tal aspecto é altamente propício para o problema aqui tratado, visto que as variáveis de decisão são os números de unidades geradoras que devem operar em cada período do horizonte de programação. Estas TICs serão discutidas em detalhes nas subseções 2.2.2, 2.2.3 e 2.2.4.

As Figuras 5(a) a 5(g) ilustram os crescimentos dos números de citações desde o ano de publicação até 2019 dos algoritmos DE, GSA, ACROA, BH, BA, SCA e GWO, respectivamente, com exceção dos algoritmos GSA, ACROA e BH, para os quais somente os dados a partir de 2016 estão expostos dada a impossibilidade de obter as informações dos anos anteriores. Nota-se a tendência clara na utilização cada vez mais ampla das TICs uma vez que estas são publicadas. Tal fato é uma consequência direta do Teorema “*No Free Lunch*” (62), que basicamente diz que não existe uma meta-heurística definitiva para resolver todos os problemas existentes, ou seja, uma TIC pode se destacar em certo problema ao mesmo tempo que apresenta baixo desempenho em outros. Existe portanto um campo vasto para melhorias das TICs existentes e proposições de novas.

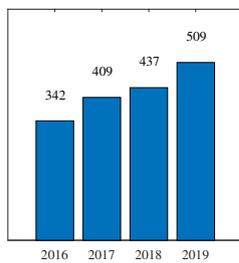
2.2.2 Sine Cosine Algorithm

O SCA não se enquadra em nenhum dos ramos descritos na subseção anterior, visto que não é baseado em conceitos evolucionários, fenômenos físicos ou comportamento de animais. De fato, este algoritmo realiza a busca com base nas funções matemáticas Seno e Cosseno.

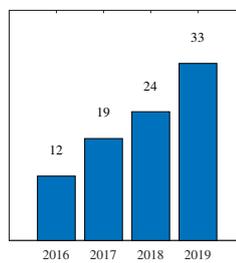
Figura 5 – Citações/ano dos algoritmos: (a) DE; (b) GSA; (c) ACROA; (d) BH; (e) BA; (f) SCA e (g) GWO



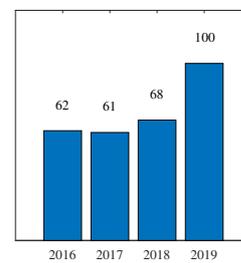
(a)



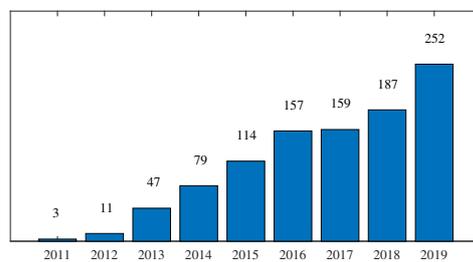
(b)



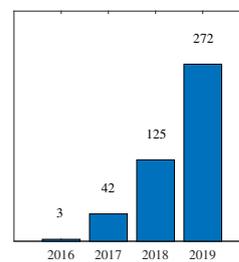
(c)



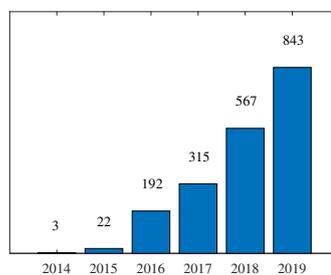
(d)



(e)



(f)



(g)

Fonte: Elaborada pelo autor (2019) com dados de: citations.springer.com, www.scopus.com e www.bookmetrix.com.

Inicialmente, são criadas múltiplas soluções candidatas aleatórias denominadas agentes de busca, os quais são então avaliados de forma a se identificar qual possui o melhor ajuste à função objetivo do problema. Iniciado o processo de busca, os agentes oscilam em direção à e na direção oposta à atual melhor solução, chamada de ponto de destino, usando um modelo baseado nas funções seno e cosseno. Outras variáveis aleatórias são adicionadas de modo que se priorize a exploração, que se dá pela busca ampla na região de solução, ou a intensificação, que se dá pela busca mais concentrada nos arredores do ponto de destino.

Durante a exploração, os agentes de busca são deslocados abruptamente no espaço de forma altamente aleatória em busca de regiões promissoras, enquanto que na intensificação estes agentes são deslocados de forma mais gradativa e com menos aleatoriedade. Destaca-se, porém, que a transição entre estas duas fases ocorre de modo suave, o que se tornará mais claro nos parágrafos que seguem.

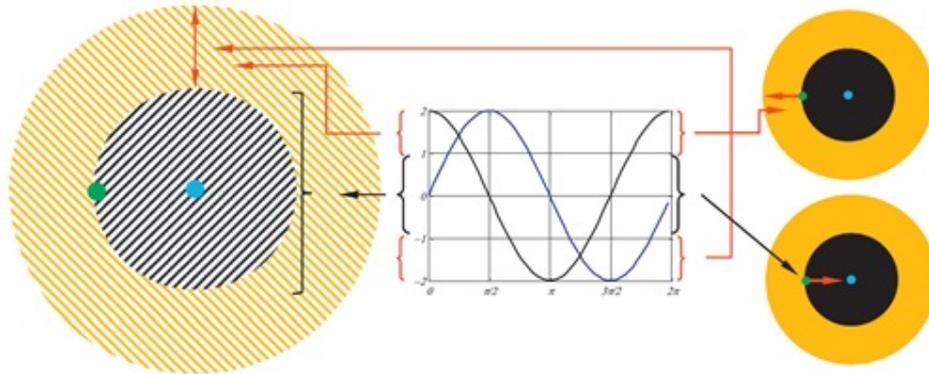
As atualizações de posição dos agentes no espaço no SCA são dadas pelas Equações 2.7, em que X_i^z é a posição do agente de busca na i -ésima dimensão da z -ésima iteração, r_2 , r_3 e r_4 são valores reais aleatórios em $[0, 2\pi]$, $[0, 2]$ e $[0, 1]$, respectivamente, e P_i^z é a posição do ponto de destino na i -ésima dimensão da z -ésima iteração. O parâmetro r_1 é responsável por gradativamente alterar o alcance das funções seno e cosseno, isto é, limitar a distância máxima a ser percorrida pelos agentes de busca, de acordo com o valor da iteração atual, conforme Equação 2.8, em que z é a iteração atual, z_{max} é o número máximo de iterações e a é uma constante denominada coeficiente de exploração. Esta equação visa equilibrar as etapas de exploração e intensificação para que as regiões promissoras sejam encontradas e para que eventualmente ocorra a convergência para a solução ótima. As variáveis r_1 , r_2 , r_3 e r_4 determinam o sentido de deslocamento do agente, estabelecem qual deve ser a magnitude do deslocamento e ponderam o efeito do ponto de destino na definição da distância a ser percorrida, com exceção da última, cuja única responsabilidade é alternar entre as funções seno e cosseno.

$$X_i^{z+1} = \begin{cases} X_i^z + r_1 \cdot \sin(r_2) \cdot |r_3 \cdot P_i^z - X_i^z|, & r_4 < 0,5 \\ X_i^z + r_1 \cdot \cos(r_2) \cdot |r_3 \cdot P_i^z - X_i^z|, & r_4 \geq 0,5 \end{cases} \quad (2.7)$$

$$r_1 = a - z \cdot \frac{a}{z_{max}} \quad (2.8)$$

Devido ao comportamento cíclico das funções seno e cosseno, torna-se possível reposicionar um agente de busca ao redor do ponto de destino. Para que a exploração do espaço seja apropriadamente efetuada, a busca também precisa ocorrer fora da região entre o agente de busca e o ponto de destino. No SCA, o aumento do alcance das funções seno e cosseno permite que este objetivo seja alcançado, como exibido na Figura 6, em que nota-se os efeitos das funções seno e cosseno com o alcance em $[-2, 2]$.

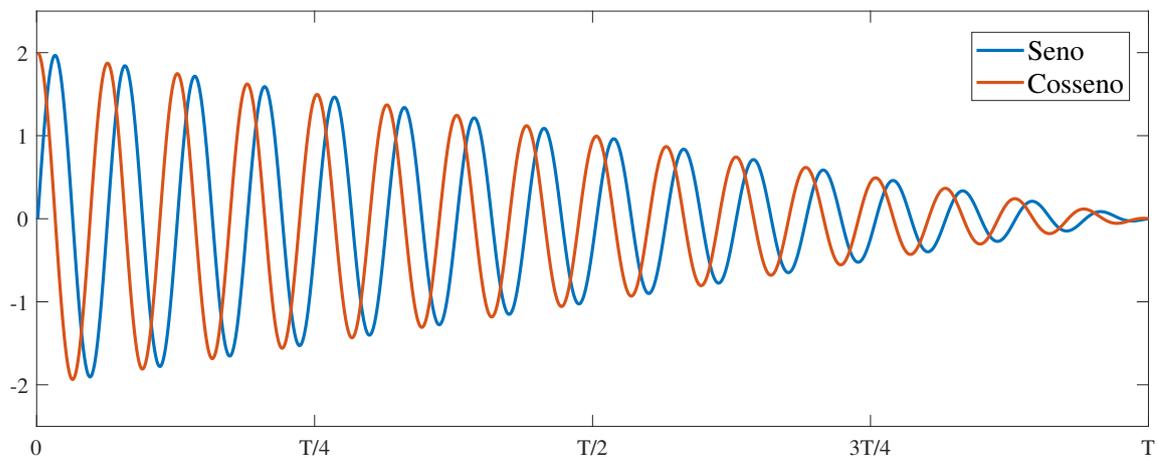
Figura 6 – Deslocamento no SCA com alcance em $[-2,2]$



Fonte: (61).

A Figura 7 exibe como a diminuição do alcance das funções acontece com a aplicação da Equação 2.8 ao longo das iterações. Nota-se pelas Figuras 6 e 7 que a exploração acontece quando o alcance está em $(1,2]$ ou $[-2,1)$, enquanto que a intensificação acontece no intervalo $[-1,1]$.

Figura 7 – Funções seno e cosseno com redução do alcance ao longo das iterações



Fonte: Elaborada pelo autor (2019).

O algoritmo é encerrado ao se atingir o número máximo de iterações estabelecido previamente. Contudo, outras formas de finalizar o algoritmo podem ser implementadas. De acordo com Mirjalili (61), o SCA é capaz, em teoria, de determinar o ponto ótimo global de problemas de otimização devido aos seguintes fatores:

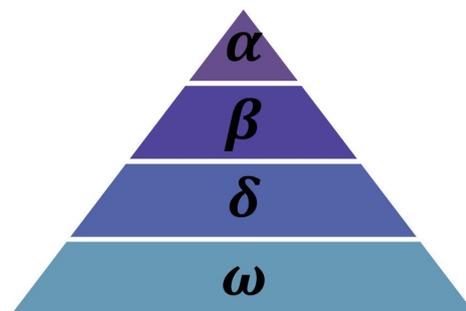
- O algoritmo cria e melhora diversas soluções iniciais aleatórias, beneficiando-se portanto de alta exploração e da capacidade de evitar ótimos locais;
- Distintas regiões do espaço são exploradas quando os parâmetros de atualização retornam valores de magnitude maior que 1;

- Regiões promissoras são varridas de forma mais concentrada quando os parâmetros de atualização retornam valores de magnitude menor que 1;
- O algoritmo transita suavemente da exploração para a intensificação utilizando um alcance adaptativo nas funções seno e cosseno;
- As informações da melhor solução de cada iteração são carregadas ao longo do processo de otimização;
- Como as soluções candidatas atualizam suas posições com base na melhor solução obtida até a iteração atual, existe uma tendência em encontrar regiões cada vez mais promissoras ao longo da otimização;
- Como o algoritmo considera o problema a ser otimizado como uma “caixa preta”, o mesmo é aplicável a problemas de variadas áreas de pesquisa, contanto que estes sejam formulados adequadamente.

2.2.3 Grey Wolf Optimizer

O desenvolvimento do algoritmo GWO foi inspirado na hierarquia social dos lobos cinzentos, a qual é dividida, do topo para a base, em α , β , δ e ω , como ilustrado na Figura 8, e em seus hábitos de caça, os quais se consistem da caça, cerco e ataque à presa. Cada categoria social desempenha um papel diferente na alcateia. O lobo α , também chamado de dominante, é responsável principalmente por tomadas de decisão, como horários de caça, descanso e locomoção. O lobo β é o braço direito do lobo α e o ajuda a tomar decisões. Os lobos δ são divididos em escoltas, sentinelas, anciões, caçadores e cuidadores. Finalmente, os lobos ω estão sujeitos à todas as outras castas e sempre são os últimos permitidos a se alimentar.

Figura 8 – Hierarquia dos Lobos Cinzentos



Fonte: (26).

Esta TIC se trata de um algoritmo populacional e é baseada em Inteligência de Exame. Os lobos α , β e δ são, respectivamente, a primeira, segunda e terceira melhores

soluções obtidas em cada iteração. Todos os outros lobos são do tipo ω , sendo portanto responsáveis por executar a busca e seguir as castas superiores. O Algoritmo 1 descreve o GWO, sendo que as variáveis nele expostas têm seus significados explicitados na Tabela 1. O parâmetro a^z é responsável por fazer com que o algoritmo transite gradualmente entre a exploração global para a intensificação na região promissora. É válido mencionar que embora o Algoritmo 1 descreva os parâmetros e indivíduos como vetores, o processo prático é efetuado em uma dimensão de cada vez, isto é, os parâmetros randômicos são atualizados para cada posição da solução candidata.

Algoritmo 1 – Descrição do GWO.

1. Iniciar a população de lobos cinzentos aleatoriamente
2. Calcular a aptidão de cada lobo
3. Definir a hierarquia ($\vec{\alpha}$, $\vec{\beta}$, $\vec{\delta}$ e $\vec{\omega}$)
4. Atribuir $z = 1$
5. Enquanto $z \leq z_{max}$, faça:
 - a) Atualizar a^z de acordo com: $a^z = a - a \cdot (z - 1) / z_{max}$
 - b) Para cada lobo \vec{X}^z
 - i. Calcular \vec{A}_1, \vec{A}_2 e \vec{A}_3 de acordo com: $\vec{A} = a^z \cdot \vec{r}_1$
 - ii. Calcular \vec{C}_1, \vec{C}_2 e \vec{C}_3 de acordo com: $\vec{C} = a \cdot \vec{r}_2$
 - iii. $\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{\alpha} - \vec{X}^z|, \vec{D}_\beta = |\vec{C}_2 \cdot \vec{\beta} - \vec{X}^z|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{\delta} - \vec{X}^z|$
 - iv. $\vec{X}_1 = \vec{\alpha} - \vec{A}_1 \cdot \vec{D}_\alpha, \vec{X}_2 = \vec{\beta} - \vec{A}_2 \cdot \vec{D}_\beta, \vec{X}_3 = \vec{\delta} - \vec{A}_3 \cdot \vec{D}_\delta$
 - v. $\vec{X}^{z+1} = (\vec{X}_1 + \vec{X}_2 + \vec{X}_3) / 3$
 - c) Calcular a aptidão de cada lobo atualizado
 - d) Atualizar a hierarquia
 - e) Incrementar $z = z + 1$
6. Retornar $\vec{\alpha}$

Percebe-se no Algoritmo 1 que, após o processo de inicialização dos lobos (soluções candidatas) e definição da primeira hierarquia, a atualização da alcateia se inicia. Se $|A| < 1$, o lobo se move dentro da região entre o mesmo e a presa (melhor solução atual), aproximando-se portanto da mesma e intensificando a busca, enquanto que se $|A| > 1$, o lobo se move para fora da região entre o mesmo e a presa, afastando-se da mesma e realizando uma exploração da região em busca de presas melhores. As Figuras 9 e 10 ilustram a dinâmica de cerco dos lobos e as possibilidades de direcionamento, respectivamente.

Os vetores \vec{A} , os quais variam no intervalo $[-2,2]$, embora tenham uma parcela de aleatoriedade, tendem a acompanhar o decréscimo linear do parâmetro a^z , enquanto que os vetores \vec{C} são totalmente randômicos no intervalo $[0,2]$. Estes têm por objetivo ponderar a influência dos lobos dominantes na definição do deslocamento, enfatizando tal influência quando $\vec{C} > 1$ e tendo o efeito contrário quando $\vec{C} < 1$.

As novas posições dos lobos cinzentos são dadas pelas médias dos vetores \vec{X} , os quais são calculados com base nos vetores \vec{A} , \vec{C} e nos lobos α , β e δ , ou seja, o processo de busca é definido com base nas posições dos lobos mais aptos. A hierarquia é reestabelecida até que se alcance o número máximo de iterações. O lobo α é então retornado como a solução ótima. É interessante notar que, no GWO, como o lobo α representa a melhor solução encontrada até o momento, o mesmo é a própria presa. Além disso, quando um lobo encontra uma solução melhor, este se torna o novo α .

Mirjalili, S. e Mirjalili, S. M. (26) destacam os seguintes pontos para evidenciar que o GWO é teoricamente capaz de resolver problemas de otimização:

- O sistema de hierarquia ajuda o algoritmo a preservar as melhores soluções ao longo do processo;
- O mecanismo de cerco cria uma região de busca circular ao redor das soluções e pode ser estendido para dimensões maiores;
- Os parâmetros probabilísticos \vec{A} e \vec{C} auxiliam na obtenção de soluções candidatas com diferentes alcances em relação à presa;
- O valor adaptativo do parâmetro a^z permite que ocorram as etapas de exploração e intensificação e que a transição entre estas seja suave;
- Estatisticamente, metade das iterações enfatizam exploração enquanto a outra metade enfatiza intensificação;
- O algoritmo possui apenas dois parâmetros principais a serem ajustados.

2.2.4 Ant Colony Optimization

O ACO foi desenvolvido com base no conceito de estigmergia, o qual caracteriza a habilidade de indivíduos se comunicarem indiretamente via alterações no ambiente visando algum benefício para o grupo. Mais especificamente, foi inspirado no mecanismo de busca por alimento de algumas espécies de formigas. Ao longo da dinâmica de tal busca, as formigas que localizam um alvo percorrem de volta o caminho traçado liberando uma substância chamada feromônio. Outras formigas tendem a percorrer trajetos em que a concentração de feromônio é mais alta, o que eleva a probabilidade de tal concentração se tornar ainda mais forte, visto que estas reforçarão a trilha de feromônio. Como mencionado

em (30), este comportamento permite que as formigas encontrem o menor trajeto entre a fonte de alimento e a colônia de forma incrivelmente eficiente.

Diversos algoritmos baseados no comportamento de formigas foram propostos, sendo o primeiro conhecido como Ant System (63; 64; 65). Todos partem da mesma ideia, porém com sutis diferenças envolvendo o processo de busca. Os conceitos principais foram agrupados em (66), dando origem assim à TIC que ficou conhecida como ACO. Informações sobre aplicações e ricas revisões sobre estes algoritmos podem ser consultados em (30) e em <http://iridia.ulb.ac.be/~mdorigo/ACO/publications.html>.

No ACO, inicialmente define-se uma população de formigas artificiais que têm, na primeira iteração, suas dimensões aleatoriamente preenchidas pelos valores contidos na região de solução (RS). Dado que os valores atribuíveis às variáveis de decisão possuem custos associados entre si, ou seja, existe um esforço intrínseco à locomoção de um valor i a um valor j , com $i, j \in RS$, define-se a matriz de custos D , em que cada ponto (i, j) contém o custo associado à locomoção entre estes valores. Em seguida, com base nestes custos, avalia-se a aptidão de cada formiga da colônia para então definir a matriz de feromônio τ , a qual recebe valores para cada posição (i, j) de acordo com as aptidões calculadas, tendo em consideração que o somatório de cada linha desta matriz deve ser igual a 1. Nas iterações seguintes, a atribuição de valores às dimensões das formigas é dada de forma estocástica de acordo com τ , isto é, melhores aptidões possuem maiores probabilidades de assimilação. Atualiza-se τ a partir das aptidões das novas formigas e assim em diante, até que se atinja o número máximo de iterações e seja retornada a melhor formiga como solução. Destaque-se que o ACO é uma técnica de otimização combinatória, ou seja, desenvolvida para problemas com regiões finitas de soluções, sendo ideal para problemas discretos.

Diferentes problemas podem exigir ajustes no algoritmo. Por exemplo, no clássico Problema do Caixeiro Viajante, em que almeja-se determinar qual é a rota com menor distância total percorrida entre um conjunto de cidades, sendo cada cidade visitada uma única vez, a atribuição de valores às dimensões de uma formiga deve ocorrer sem repetição de valores. No Problema de Otimização da Operação Diária de UHEs, o mesmo número de unidades geradoras pode ser atribuído em vários períodos do horizonte de programação, logo deve-se permitir que as dimensões da formiga recebem valores repetidos.

Embora os algoritmos SCA e GWO tenham sido implementados pelo autor deste trabalho, o algoritmo ACO foi obtido em (67) (direitos autorais no Anexo A), o qual fornece implementações do ACO para o Problema do Caixeiro Viajante, o Problema da Atribuição Quadrática e o Problema da Mochila, os quais são problemas de otimização combinatória amplamente utilizados para testes de TICs. O “corpo” do algoritmo foi mantido, adaptando-se somente as linhas de código responsáveis pela função objetivo e restrições do problema aqui tratado.

2.2.5 Modificação no Sine Cosine Algorithm

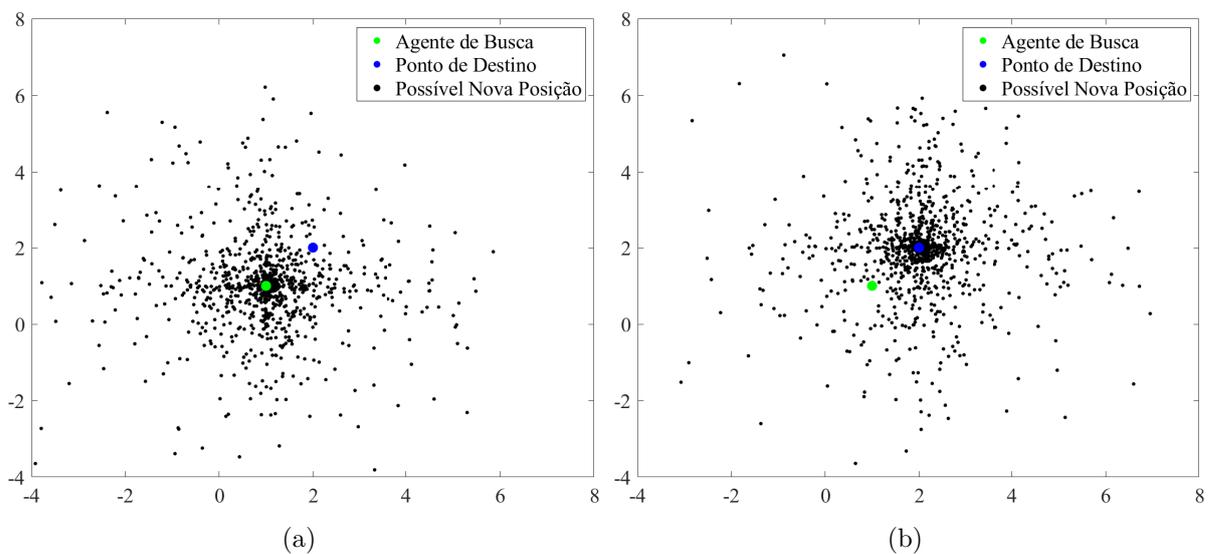
Durante as simulações percebeu-se que ao utilizar as Equações 2.7 originais, as novas soluções se posicionavam ao redor do agente de busca em vez de se posicionarem em torno do ponto de destino, conforme originalmente descrito em (61), o que é mostrado na Figura 11(a). Esta figura exemplifica um caso de duas dimensões em que, a partir de uma solução candidata, várias possibilidades de novas posições são geradas em relação ao ponto de destino.

De forma a posicionar as novas soluções em torno do ponto de destino, o que está de acordo com a explicação originalmente provida em (61), modificou-se as Equações 2.7, obtendo as novas Equações 2.9. Recordar-se que o ponto de destino nada mais é que a solução que apresentou a melhor aptidão em uma iteração em particular e que, ao fim do processo iterativo, é retornada como solução final do algoritmo.

$$X_i^{z+1} = \begin{cases} P_i^z + r_1 \cdot \sin(r_2) \cdot |r_3 \cdot P_i^z - X_i^z|, & r_4 < 0,5 \\ P_i^z + r_1 \cdot \cos(r_2) \cdot |r_3 \cdot P_i^z - X_i^z|, & r_4 \geq 0,5 \end{cases} \quad (2.9)$$

Nota-se que o primeiro termo após a igualdade nas Equações 2.9 passa a ser o ponto de destino em vez do agente de busca. Esta modificação faz com que os novos agentes se posicionem ao redor do ponto de destino, como pode ser observado na Figura 11(b). Verificou-se empiricamente que tal modificação melhorou consideravelmente a convergência do algoritmo ao longo das simulações, o que será exposto no Capítulo 4.

Figura 11 – Possibilidades de posição para novas soluções via Equações (a) 2.7 e (b) 2.9



Fonte: Elaborada pelo autor (2019).

2.2.6 Adaptações em Técnicas de Inteligência Computacional

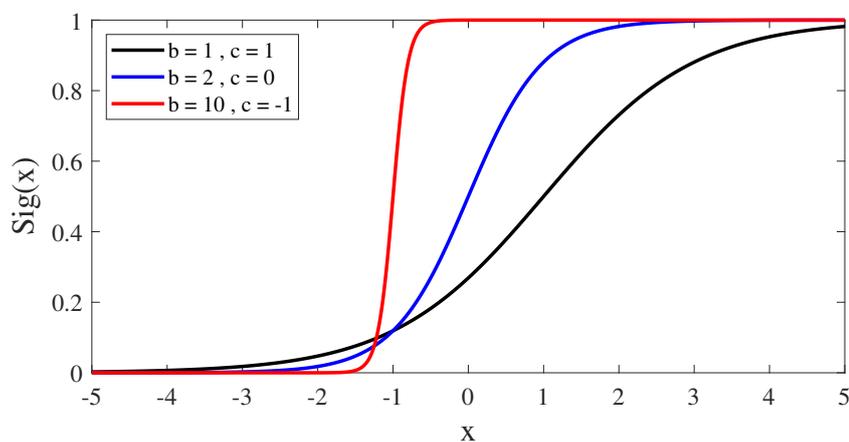
É comum na literatura que melhorias sejam aplicadas a TICs. Técnicas como o Elitismo e o Aprendizado Baseado em Oposição são frequentemente aplicadas em TICs de modo a melhorar seus desempenhos. A primeira se baseia basicamente na transferência do melhor indivíduo ao longo das gerações (iterações). A segunda consiste da criação de mais indivíduos para realizarem a busca, sendo que estes não se posicionam conforma as equações de atualização da TIC em questão, porém se posicionam sempre de forma simetricamente oposta em relação aos indivíduos originais dentro da região viável.

Embora as adaptações citadas anteriormente sejam relativamente simples, modificações mais complexas podem ser aplicadas de modo a permitir que TICs sejam aplicadas em problemas de distintas naturezas. A maioria das TICs opera originalmente no domínio dos números reais, ou seja, as variáveis de decisão assumem valores contínuos. A princípio, portanto, estas TICs não são ideias para problemas discretos e/ou binários.

Uma abordagem simples para resolver este obstáculo se dá pela realização de arredondamentos das variáveis de decisão após a atualização de posição realizada pela TIC. Entretanto, ferramentas mais aprimoradas para lidar com tais situações podem ser encontradas na literatura, principalmente para problemas binários.

Uma abordagem que se mostrou muito eficiente em diversos problemas binários é a utilização da função Sigmoide, como em (68), em que se propõe uma versão binária do PSO. Esta função, descrita na Equação 2.10, têm como saída valores no intervalo $[0,1]$. Nesta equação, o parâmetro b determina quão abrupta é a transição do valor nulo ao unitário. O parâmetro c estabelece qual abscissa marca a metade da transição. É trivial notar na Equação 2.10 que a função vale exatamente 0,5 quando x assume um valor igual a c . A Figura 12 exemplifica diferentes funções Sigmoide com variados valores de b e c .

Figura 12 – Sigmoides com distintos parâmetros



Fonte: Elaborada pelo autor (2019).

$$Sig(x) = \frac{1}{1 + e^{-b \cdot (x-c)}} \quad (2.10)$$

Nas adaptações binárias de TICs, os valores calculados pelas equações de atualização de posição são atribuídas à variável x da Equação 2.10. O Algoritmo 2 descreve as linhas de comando que devem substituir o passo 5.b)v. do Algoritmo 1 para que o GWO se torne binário, sendo $rand$ um valor aleatório em $[0,1]$. Esta modificação foi proposta em (69) e estabelece um mecanismo que permite que os indivíduos realizem os processos de exploração e intensificação com base em alternâncias entre os valores nulo e unitário, tornando as TICs poderosas ferramentas para resolução de problemas binários. É válido destacar que os valores “10” e “0,5” para b e c , respectivamente, são os valores propostos em (69). Nenhuma investigação a respeito destes valores foi realizada neste trabalho.

Algoritmo 2 – Passos para adaptação binária do GWO.

$$\begin{aligned} \text{v } Sig &= \frac{1}{1 + e^{-10 \cdot (x-0,5)}}, \text{ com } x = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \\ \text{vi } \vec{X}^{t+1} &= \begin{cases} 1, & \text{se } Sig \geq rand \\ 0, & \text{caso contrário} \end{cases} \end{aligned}$$

Algoritmos binários podem ser de grande utilidade em problemas discretos. Detalhes de como as adaptações binárias de TICs foram aplicadas no problema tratado neste trabalho encontram-se expostos na Seção a seguir. É válido mencionar que abordagens alternativas de como adaptar uma TIC para aplicação em problemas binários podem ser consultadas em (70), (71), (72) e (73), as quais propõem versões binárias dos algoritmos ABC, FOA, BA e WOA, respectivamente. No entanto, tais abordagens não foram avaliadas neste trabalho.

2.2.7 Otimização Discreta via Algoritmos Binários

Conforme diretrizes expostas previamente, os algoritmos SCA e GWO foram adaptados para problemas binários. Assim como no Algoritmo 2, o qual descreve os passos para adaptação do GWO, o SCA foi adaptado, ou seja, os valores resultantes das expressões de atualização de posição (Equações 2.7 e 2.9) foram sujeitos à função Sigmoide (Equação 2.10) para que os valores binários pudessem ser estabelecidos.

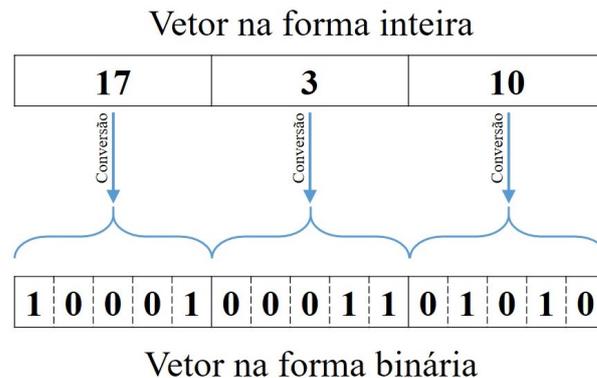
É de grande importância recordar que em TICs populacionais, ou seja, que possuem múltiplas soluções candidatas, como o SCA e GWO, as soluções iniciais são geradas de forma completamente aleatória dentro da região de busca. No entanto, em problemas discretos, a etapa de inicialização dos indivíduos deve passar obrigatoriamente por um processo de arredondamento, dada a imposição de que as variáveis devem ser inteiras. Porém, enfatiza-se que este arredondamento não é efetuado durante as iterações, o que forçaria os valores contínuos a serem inteiros. De fato, este é efetuado apenas na definição

das soluções iniciais. Se o problema for binário, a inicialização se dá com a geração de valores aleatórios em $[0,1]$ e subsequentes arredondamentos ou com a utilização de alguma função específica que retorne somente valores nulos ou unitários.

De posse das versões binárias dos algoritmos SCA e GWO, ainda se faz necessário discutir como tais técnicas podem ser aplicadas a problemas discretos, visto que, no problema de otimização tratado neste trabalho, as variáveis de decisão são os números de unidades geradoras que devem operar na UHE ao longo dos períodos do dia seguinte.

Para realizar tal procedimento, basta, a princípio, transformar os vetores de valores inteiros das soluções candidatas iniciais em vetores de valores binários, sempre respeitando o número máximo de *bits* (n_{bits}) inerente ao problema em questão. No caso da UHE estudada, como o número máximo de unidades geradoras é cinco, todos os valores inteiros devem ocupar três *bits*, ou seja, em um horizonte de programação de 24 horas discretizado de meia em meia hora, o vetor discreto teria 48 dimensões, enquanto que o vetor binário equivalente teria 144 dimensões. Se em um problema em particular, por exemplo, o valor máximo de uma variável de decisão é nove, o correspondente binário deverá ocupar quatro *bits*, mesmo que ao longo da otimização esta variável tenha valores que não necessitem de quatro *bits* em suas versões binárias. A Figura 13 exemplifica uma conversão de um vetor discreto de três posições para o vetor binário equivalente, em que as três variáveis de decisão devem ter valores em $\{x \in \mathbb{Z}/2 \leq x \leq 20\}$.

Figura 13 – Conversão de um vetor discreto para o vetor binário equivalente



Fonte: Elaborada pelo autor (2019).

Contudo, deve-se atentar para duas etapas de grande importância ao se utilizar TICs binárias para resolução de problemas discretos. A primeira diz respeito à Função Objetivo (FOB), a qual é responsável por fornecer as aptidões dos indivíduos que são gerados ao longo da otimização. A segunda diz respeito a tratamentos referentes aos limites inferiores e superiores das variáveis de decisão.

Se o problema tratado é de origem discreta, a FOB realizará os cálculos assumindo os valores inteiros das variáveis de decisão. Portanto, é crucial que os vetores binários sejam

convertidos para suas formas decimais, avaliados pela FOB e então convertidos novamente para suas formas binárias para que a TIC binário volte a executar os procedimentos de atualização de posições dos indivíduos. Alternativamente, pode-se utilizar uma variável auxiliar para armazenar as formas decimais dos vetores e calcular os valores das FOBs.

Em relação aos limites das variáveis, frequentemente problemas reais de otimização permitem extração de informações que resultem em uma redução da região de busca, ou seja, no estabelecimento de limites inferiores e superiores, o que aumenta a probabilidade de sucesso da TIC. Conforme explicado na Seção 3.1, o problema tratado neste trabalho permite que limites sejam estabelecidos com base nas metas de geração impostas à UHE. Porém ao se utilizar uma TIC binária para resolver um problema discreto, a utilização dos limites deixa de ser prontamente aplicável devido aos seguintes fatores:

- Se, por exemplo, uma variável x é tal que $7 \leq x \leq 11$, os correspondentes binários dos limites inferior e superior são, respectivamente, 0111 e 1011. É equivocado afirmar que cada bit de x é maior ou igual ao bit correspondente do limite inferior (7) e menor ou igual ao bit correspondente do limite superior (11). No exemplo em questão, não faz sentido afirmar que o segundo bit, da esquerda para a direita, é maior ou igual a 1 e menor ou igual a 0. Além disso, percebe-se que se o quarto bit é estabelecido como sendo maior ou igual a 1, o algoritmo impediria, por exemplo, que tal variável assumisse o vetor binário 1010 (10 no sistema decimal), que é um valor dentro da região viável. Conclui-se então que a utilização dos limites não pode ser feita da forma convencional.
- Ainda no mesmo exemplo em que $7 \leq x \leq 11$, o correspondente binário do decimal 11 possui 4 *bits*, o que significa que a TIC binária eventualmente gerará indivíduos que possuem vetores de 4 *bits* que extrapolam o limite superior (neste exemplo, qualquer valor de 12 a 15). Tal ocorrência deve ser contornada com alguma estratégia.

Para lidar com os dois potenciais problemas citados, a cada n_{bits} atualizações de posição por parte da TIC binária, converteu-se o vetor composto por estes *bits* para decimal e este foi comparado aos limites inferior e superior da variável de decisão em questão. Enquanto o valor decimal violasse os limites, atribui-se às n_{bits} posições do vetor, uma a uma, os valores 0 ou 1 aleatoriamente, ou seja, executou-se um *loop* até que a parte inviável do indivíduo se tornasse viável. Tal abordagem mantém os indivíduos dentro da região viável, contornando assim os obstáculos de se utilizar uma TIC binária para resolver um problema discreto. Tal processo aumenta o esforço computacional, porém não ao ponto de torná-lo inaplicável, o que será exposto de modo mais claro na subseção 4.2.3. O Algoritmo 3 descreve o algoritmo GWO binário (GWO_b) adaptado para problemas discretos. O SCA binário (SCA_b) ou qualquer outra TIC pode ser implementada de maneira análoga.

Algoritmo 3 – GWO binário para problemas discretos.

1. Iniciar a população de lobos cinzentos aleatoriamente utilizando valores inteiros
2. Calcular a aptidão de cada lobo
3. Definir a hierarquia e converter os lobos para suas versões binárias (cada valor discreto se torna n_{bits} posições no lobo binário correspondente) ($\vec{\alpha}$, $\vec{\beta}$, $\vec{\delta}$ e $\vec{\omega}$)
4. Atribuir $z = 1$
5. Enquanto $z \leq z_{max}$, faça:
 - a) Atualizar a^z de acordo com: $a^z = a - a.(z - 1)/z_{max}$
 - b) Para cada lobo \vec{X}^z
 - i. Calcular \vec{A}_1, \vec{A}_2 e \vec{A}_3 de acordo com: $\vec{A} = a^z \cdot \vec{r}_1$
 - ii. Calcular \vec{C}_1, \vec{C}_2 e \vec{C}_3 de acordo com: $\vec{C} = a \cdot \vec{r}_2$
 - iii. $\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{\alpha}^z - \vec{X}^z|$, $\vec{D}_\beta = |\vec{C}_2 \cdot \vec{\beta}^z - \vec{X}^z|$, $\vec{D}_\delta = |\vec{C}_3 \cdot \vec{\delta}^z - \vec{X}^z|$
 - iv. $\vec{X}_1 = \vec{\alpha}^z - \vec{A}_1 \cdot \vec{D}_\alpha$, $\vec{X}_2 = \vec{\beta}^z - \vec{A}_2 \cdot \vec{D}_\beta$, $\vec{X}_3 = \vec{\delta}^z - \vec{A}_3 \cdot \vec{D}_\delta$
 - v. $Sig = 1/(1 + e^{-10 \cdot ((\vec{X}_1 + \vec{X}_2 + \vec{X}_3)/3 - 0.5)})$
 - vi. $\vec{X}^{z+1} = \begin{cases} 1, & \text{se } Sig \geq rand \\ 0, & \text{caso contrário} \end{cases}$
 - vii. Varrer o lobo binário de n_{bits} em n_{bits} bits
 - A. Enquanto o valor decimal deste conjunto violar o limite inferior ou superior, gerar um novo conjunto de modo randômico
 - c) Converter os lobos atualizados para suas versões decimais
 - d) Calcular a aptidão de cada lobo atualizado
 - e) Converter os lobos atualizados para suas versões binárias
 - f) Atualizar a hierarquia
 - g) Incrementar $z = z + 1$
6. Retornar $\vec{\alpha}$ convertido para sua forma decimal

Apesar de simples, a atribuição randômica de valores binários para parcelas inviáveis dos indivíduos contorna os potenciais obstáculos e é suficiente para realizar a investigação almejada neste trabalho. Ainda assim, em estudos futuros, deseja-se elaborar modos menos computacionalmente exaustivos e mais eficazes em relação à qualidade dos novos valores. O capítulo seguinte se dedica a apresentar o modelo de usina hidrelétrica a ser utilizado e submetido às otimizações via inteligência computacional.

3 MODELO DE USINA HIDRELÉTRICA

Diversas são as formas de modelar uma UHE matematicamente. Geralmente, o ONS trata as perdas hidráulicas como um valor constante, em metros, ou uma porcentagem da altura de queda bruta, de acordo com características de cada usina (tais dados são de domínio público e consultáveis em <https://bit.ly/3dkGKqN> mediante cadastro em <https://sintegre.ons.org.br/>). No entanto, é comum na literatura, como em (17; 19), que tais perdas sejam escritas em função do coeficiente de perdas hidráulicas (k_{ph}) e da vazão turbinada (q), conforme Equação 3.1, sendo k_{ph} determinado a partir de características do conduto forçado, como comprimento, diâmetro e rugosidade. Além disso, variações no nível do reservatório podem ou não ser contabilizadas. Estas e outras considerações podem ser levadas em conta de acordo com uma criteriosa análise do quanto estas afetam os resultados obtidos. No planejamento diário da operação de UHEs com extenso reservatório, por exemplo, o nível montante pode ser considerado constante dada a insignificante variação deste parâmetro em um período tão curto de tempo, o que é especialmente válido para usinas operadas a fio d'água, isto é, usinas que naturalmente apresentam variações de baixa magnitude no nível montante.

$$h_{ph} = k_{ph} \cdot q^2 \quad (3.1)$$

Neste trabalho, utilizou-se a formulação proposta em (21; 23) para modelar a UHE estudada. Em (23), funções de perdas de potência são obtidas para todas as possíveis configurações de máquinas e estas perdas são associadas a custos monetários. Também considerando custos de partidas e paradas de máquinas, a função objetivo visa minimizar o custo diário de operação da UHE Itaipu Binacional. Em (21), a abordagem baseada em custos é abandonada, ou seja, os custos de partidas e paradas não são levados em consideração. O modelo visa minimizar as perdas totais e é expandido para que múltiplas UHEs sejam otimizadas simultaneamente.

A escolha de tal formulação decorre do fato de a UHE estudada possuir, assim como a UHE Itaipu, todas as unidades geradoras iguais, ou seja, todos os geradores e turbinas apresentam as mesmas características. Este fator é de grande importância, pois o problema de se determinar quais unidades geradoras estarão ligadas ou desligadas e quanto cada uma deve gerar em cada período do horizonte de programação se torna um problema de se determinar quantas unidades geradoras estarão ligadas. A operação ótima em uma UHE com unidades geradoras idênticas se dá pela distribuição igualitária da potência demandada entre as unidades geradoras ligadas (12). Portanto, independente de quantas unidades geradoras entrem em operação, sabe-se que suas gerações serão iguais. Tal fato simplifica o problema, pois dispensa a necessidade de se determinar quanto cada unidade geradora deve suprir, ou seja, o problema se torna uma determinação de quantas unidades geradoras devem ser acionadas em cada período do horizonte de programação.

A formulação escolhida tem como base a definição de três tipos de perdas em uma UHE, as quais, quando somadas, resultam nas perdas totais a serem utilizadas para ajuste de funções de perdas. Tais funções desempenham um papel fundamental neste modelo de UHEs. Para cada possibilidade de número de unidades geradoras ligadas, há uma função. As perdas hidráulicas (p_1) são decorrentes, basicamente, do atrito entre a água e os dutos de passagem. Tais perdas estão diretamente relacionadas ao coeficiente de perdas hidráulicas. As perdas por elevação do nível jusante (p_2) estão ligadas ao fato de o nível da bacia a jusante se elevar ao se turbinar e/ou verter água, o que causa diminuição da altura de queda, que por sua vez tende a reduzir a geração, o que é facilmente deduzível ao se analisar a Equação 2.5. As perdas por eficiência das turbinas (p_3) são consequência das mudanças nos pontos de operação das unidades geradoras, visto que diferentes valores de vazão turbinada e altura de queda implicam em distintos valores de eficiência das máquinas.

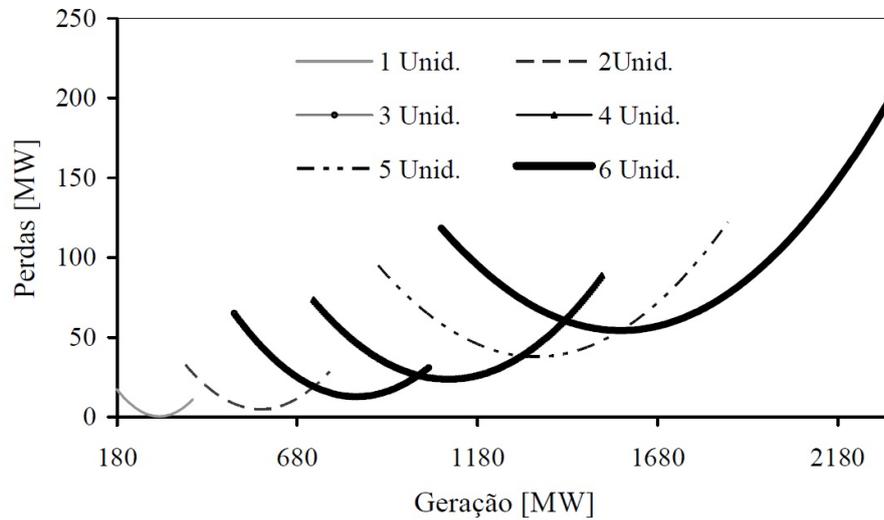
3.1 DESCRIÇÃO DO MODELO DE REFERÊNCIA

A primeira etapa da formulação em questão se dá pela obtenção das mencionadas funções de perdas de potência. Estas funções compõem parte da função objetivo do problema a ser otimizado, o que se tornará mais claro adiante. Para obtenção das mesmas, os seguintes dados da UHE são necessários:

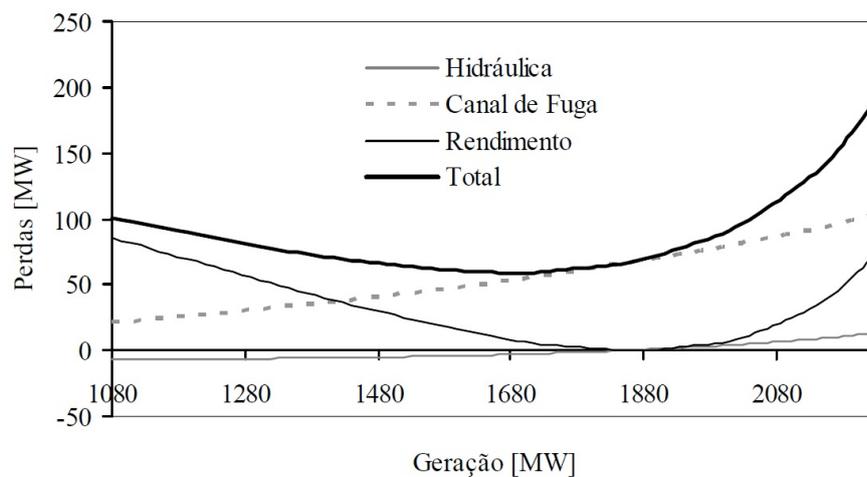
- Número total de unidades geradoras na UHE (n_{ug});
- Coeficiente de perdas hidráulicas (k_{ph}) ou altura de perdas hidráulicas (h_{ph}), de acordo com o modelo matemático da UHE;
- Polinômio da curva de eficiência dos geradores, o qual fornece a eficiência do gerador (η_{ger}) como uma função da potência gerada (p_g);
- Curva de eficiência das turbinas, a qual fornece a eficiência da turbina (η_{tur}) como função da altura de queda líquida (h_{ql}) e da vazão turbinada por uma unidade (q), ou seja, a vazão turbinada total (q_{tot}) dividida pelo número de unidades geradoras em operação (n);
- Valores mínimo (q_{min}) e máximo (q_{max}) de vazão turbinada por uma unidade, os quais podem ser extraídos da Curva Colina;
- Nível do reservatório (h_r), o qual é tratado como uma constante neste modelo;
- Polinômio vazão – nível jusante, o qual fornece o nível a jusante (h_j) como uma função da vazão defluente (Q). Esta, por sua vez, é dada pela soma de q_{tot} com o vertimento.

Uma vez obtidos todos os dados da UHE, deve-se aplicar o Algoritmo 4 para que se obtenha um conjunto de pontos bidimensionais que relacionam valores de potência gerada a valores de perdas de potência, sendo que cada possibilidade de configuração de máquinas possui um conjunto distinto. Os conjuntos são então ajustados por polinômios, dando origem às funções de perdas. É aconselhável utilizar interpolação por partes para os ajustes em vez de um polinômio único por conjunto, pois desta forma evita-se a possível incapacidade de se representar da melhor forma possível o comportamento dos pontos. As Figuras 14(a) e 14(b) apresentem as funções de perdas e as componentes p_1 , p_2 e p_3 para o caso de 6 unidades, respectivamente, obtidas ao se aplicar o algoritmo na UHE Itumbiara.

Figura 14 – (a) Funções de Perdas e (b) componentes de perdas com 6 unidades geradoras na UHE Itumbiara



(a)



(b)

Fonte: (21).

Algoritmo 4 – Passos para obtenção das Funções de Perdas de Potência.

1. Variar n de 1 a n_{ug} ;

- a) Variar q_{tot} de $n \cdot q_{min}$ a $n \cdot q_{max}$, ou seja, a vazão em cada turbina (q) vale q_{tot}/n ;
- i. Calcular h_j utilizando o Polinômio vazão – nível jusante;
 - ii. Determinar h_{ph} via Equação 3.1 ou utilizar seu valor predefinido, de acordo com o modelo da UHE, e então calcular h_{ql} via Equação 3.2;

$$h_{ql}(q) = h_r - h_j(q) - h_{ph} \quad (3.2)$$

- iii. Com base nos limites de cavitação e nos polinômios que os descrevem, verificar a viabilidade e q em relação a h_{ql} . Se viável, prosseguir para o passo “iv”. Se não, retornar ao passo “a)” com um novo valor de q_{tot} ;
- iv. Calcular a potência mecânica (p_m) em MW para uma das n unidades via Equação 3.3, na qual g é a aceleração da gravidade, σ é a densidade da água no reservatório e $k = 10^{-6}$ transforma W em MW;

$$p_m = k \cdot g \cdot \sigma \cdot \eta_{tur}(h_{ql}, q) \cdot h_{ql} \cdot q \quad (3.3)$$

- v. Utilizar o polinômio de eficiência dos geradores e um processo iterativo, como o Método de Newton-Raphson, para resolver a Equação 3.4 e obter p_g para o valor atual de q_{tot} e n ;

$$p_g = p_m \cdot \eta_{ger}(p_g) \quad (3.4)$$

- vi. Calcular p_1 , p_2 e p_3 utilizando as Equações 3.5, 3.6 e 3.7, respectivamente, sendo η_{max} a eficiência máxima das turbinas. As perdas totais (per_{tot}) em MW são dadas pela soma das três componentes;

$$p_1 = k \cdot g \cdot \sigma \cdot \eta_{ger}(p_g) \cdot \eta_{tur}(h_{ql}(q), q) \cdot h_{ph}(q) \cdot q_{tot} \quad (3.5)$$

$$p_2 = k \cdot g \cdot \sigma \cdot \eta_{ger}(p_g) \cdot \eta_{tur}(h_{ql}(q), q) \cdot (h_j(q) - h_j(q_{min})) \cdot q_{tot} \quad (3.6)$$

$$p_3 = k \cdot g \cdot \sigma \cdot \eta_{ger}(p_g) \cdot (\eta_{max} - \eta_{tur}(h_{ql}(q), q)) \cdot h_{ql}(q) \cdot q_{tot} \quad (3.7)$$

- vii. Armazenar per_{tot} e a geração total (p_{gtot}) calculada pela Equação 3.8;

$$p_{gtot} = n \cdot p_g \quad (3.8)$$

- viii. Determinar as gerações mínimas (p_{min_n}) e máximas (p_{max_n}) para cada n , as quais ocorrem quando q_{tot} é igual a $n \cdot q_{min}$ e $n \cdot q_{max}$, respectivamente;
- ix. Encerrar o algoritmo se n for igual a n_{nug} .

Definidas as funções de perdas, a próxima etapa consiste de fato da otimização da operação diária, ou seja, da determinação de quantas unidades geradoras devem operar ao longo das próximas 24 horas de forma que o custo seja o menor possível.

Para tal, Arce Encina (23) propõe a formulação descrita pelas Equações 3.9 a 3.11, cujos parâmetros são descritos na Tabela 2. O número de partidas ou paradas ocorridas é dado pelo módulo da diferença entre o número de unidades geradoras em certo período e o número de unidades geradoras no período imediatamente anterior. Percebe-se então que a função objetivo descrita na Equação 3.9 é dada pela soma de custos associados a partidas e paradas de unidades geradoras com custos associados às perdas de potência oriundas da operação com n unidades.

A restrição 3.10 diz respeito à integralidade das variáveis de decisão, enquanto que a restrição 3.11 representa seus limites inferiores e superiores. Estes limites, ou seja, os números mínimos e máximos de unidades geradoras que podem atender as demandas, dependem dos valores destas. É possível que certa quantidade de unidades geradoras tenha um valor de geração mínima superior à meta de geração ou um valor de geração máxima inferior à tal meta. O cálculo dos limites, que obviamente antecede o processo de otimização, se dá com base no Algoritmo 5 e é importante para que se defina a região viável de solução.

$$\min \sum_{t=1}^T c_{pp} \cdot |n_t - n_{t-1}| + c_{per} \cdot fun_n(d_t) \quad (3.9)$$

s.a:

$$n_t \in \mathbb{Z} \quad (3.10)$$

$$n_{t_{min}}(d_t) \leq n_t \leq n_{t_{max}}(d_t) \quad (3.11)$$

Tabela 2 – Parâmetros nas Equações 3.9 a 3.11

Parâmetro	Descrição
T	Número de períodos no horizonte de programação
c_{pp}	Custo de uma partida ou parada de máquina
c_{per}	Valor financeiro de 1 MWh
n_t	Número de unidades geradoras operando no período t
fun_n	Função de perdas para n unidades
d_t	Meta de geração para o período t
$n_{t_{min}}$	Limite inferior de unidades geradoras para atender a demanda no período t
$n_{t_{max}}$	Limite superior de unidades geradoras para atender a demanda no período t

Fonte: Elaborada pelo autor (2019).

Algoritmo 5 – Definição dos limites das variáveis de decisão.

1. Faça 1: faça k variar de 1 a T ;
 - a) Faça 2: faça m variar de 1 até n_{ug} com passo 1;
 - i. Se $p_{max_m} > d_k$;
 - A. $n_{t_{min}} = m$;
 - B. Interromper “Faça 2”;
 - b) Faça 3: faça m variar de n_{ug} a 1 com passo -1;
 - i. Se $p_{min_m} < d_k$;
 - A. $n_{t_{max}} = m$;
 - B. Interromper “Faça 3”;
 - c) Encerrar se k for igual a T .

O problema apresentado se trata de uma programação não linear inteira. A não linearidade se deve à presença da função modular na função objetivo. Em (21; 23), resolve-se o problema via Programação Dinâmica. Efetuada a otimização, obtêm-se o número de unidades geradoras que devem operar ao longo do horizonte de programação de modo que o custo total seja minimizado.

É válido observar que caso o problema seja otimizado com um custo de partidas e paradas nulo, a otimização se torna uma minimização das perdas, o que é especialmente recomendado em situações em que os recursos hídricos tendem a ser limitados, ou seja, em épocas de baixa precipitação pluviométrica, visto que menos perdas implicam em uma operação mais eficiente.

Por outro lado, se o custo de perdas for considerado nulo, o problema se torna uma minimização de partidas e paradas, o que é recomendável em situações em que os recursos sejam abundantes a ponto de ocorrer vertimento, visto que neste contexto não há motivo para se garantir uma operação mais eficiente, sendo mais apropriado que se evite ligamentos e desligamentos de unidades geradoras, pois estes são os principais motivos para redução de suas vidas úteis.

Embora a seção a seguir não se relacione aos trabalhos de Arce Encina (21; 23), ela também aborda aspectos referentes à modelagem matemática da UHE. Mais especificamente, apresenta-se as diretrizes aplicadas neste trabalho para se obter o modelo que representa a curva de eficiência das turbinas ao longo das simulações.

3.2 ANÁLISE E MODELAGEM DA CURVA COLINA

Ao se tratar do problema de otimização da operação de uma UHE, ou qualquer problema que envolva a modelagem matemática de sistemas reais, é desejável que os parâmetros do sistema sejam representados o mais próximos possíveis da realidade (74; 75; 76) para que a solução obtida e os demais resultados tenham o máximo de coerência e precisão. Dentro deste contexto, em relação à curva de eficiência das turbinas (CET), é necessário determinar uma função / “caixa preta” que forneça a eficiência das mesmas como saída para quaisquer valores de entrada de vazão turbinada unitária em metros cúbicos por segundo e altura de queda líquida em metros.

As CETs são originalmente fornecidas pelo fabricante das turbinas como um conjunto de pontos tridimensionais. Portanto, obter uma função / “caixa preta” apropriada não é trivial. Neste trabalho, explorou-se uma nova abordagem para o ajuste de CETs, a qual visa gerar uma superfície suave com erros pequenos em relação aos dados originais.

Polinômios são comumente aplicados nesta etapa. Como vantagem, suas derivadas são facilmente determinadas, o que pode ser útil durante a implementação da ferramenta de otimização. Pouca exploração de diferentes metodologias neste assunto é encontrada na literatura. De fato, não foi encontrado nenhum trabalho que visasse estudar maneiras distintas de obter uma função / “caixa preta” para modelar CETs. Neste trabalho, o algoritmo de clusterização *Fuzzy C-Means* (FCM) (77), o sistema *Adaptive-Network-Based Fuzzy Inference System* (ANFIS) (78) e o sistema *Extreme Learning Adaptive-Network-Based Fuzzy Inference System* (ELANFIS) (79) foram explorados. Ressalta-se que a aplicação de tais técnicas neste problema é uma proposta ainda não estudada na literatura. Os parágrafos a seguir descrevem de forma concisa as técnicas acima mencionadas.

Técnicas de clusterização são usadas em muitas áreas de pesquisa, por exemplo, reconhecimento de padrões (80), segmentação de imagens (81; 82), mineração de dados (83) e classificação (84; 85). Esses algoritmos agrupam dados que possuem características semelhantes e muitos são baseados no Sistema Fuzzy (SF), como o FCM e suas variantes: *Possibilistic C-Means* (86), *Fuzzy C-Numbers* (87), *Fuzzy Possibilistic C-Means* (88), *Entropy-Regularized FCM* (89), *Partition Simplification FCM* (90), *Interval Type-2 Fuzzy C-Means* (91), *Possibilistic Fuzzy C-Means* (92), *Single Pass Fuzzy C Means* (93), *Interval Type-2 Possibilistic C-Means* (94), *Random Sampling Plus Extension Fuzzy C-Means* (95), *Geometric Progressive Fuzzy C-Means* (96), *Minimum Sample Estimate Random Fuzzy C-Means* (96) e *Interval Type-2 Fuzzy Possibilistic C-Means* (97).

A arquitetura ANFIS é um sistema híbrido que combina representação do conhecimento, tolerância à imprecisões / incertezas e interpretabilidade do SF com a adaptabilidade e capacidade de aprendizado de Redes Neurais Artificiais (RNAs) visando melhor desempenho. Localização de falhas em linhas de transmissão (98), restauração de imagens (99) e controle de plantas térmicas (100) são exemplos de áreas de pesquisa que utilizam ANFIS.

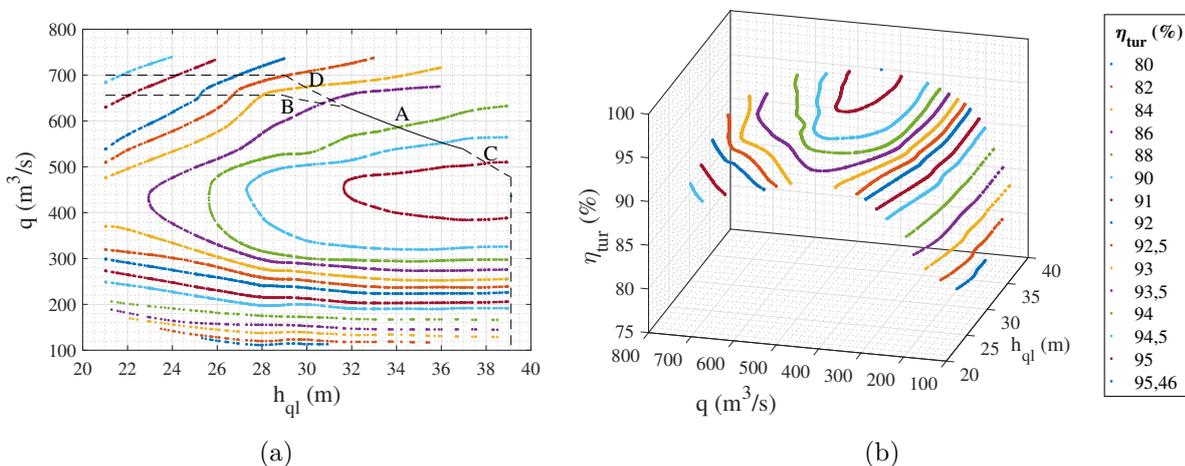
A técnica Extreme Learning Machine (ELM) (101) é uma derivação da RNA *feed-forward* de uma camada oculta que aumenta significativamente a velocidade de aprendizado ao utilizar um método de mínimos quadráticos para aproximar os pesos dos neurônios a seus valores ótimos em cada função de ativação, descartando a etapa de refinamento dos parâmetros da camada oculta (102). Aplicações incluem *soft sensors* (103), classificação (104) e reconhecimento de emoções (105). Classificações equivocadas podem ocorrer devido à geração randômica dos parâmetros dos nós ocultos e ao fato de estes permanecerem inalterados durante o treinamento (106).

O método ELANFIS é a combinação dos sistemas ELM e ANFIS. A incorporação do SF à arquitetura permite a representação de conhecimento, o que evita a aleatoriedade típica do ELM. Além disso, o algoritmo híbrido de aprendizagem presente no ANFIS é eliminado, reduzindo assim a complexidade computacional. Algumas aplicações são regressão (107), controle (108), classificação (109) e previsão de séries temporais caóticas (110). Ambos ANFIS e ELANFIS possuem o número de funções de pertinência (N_{FP}) e o número de épocas de treinamento (N_E) como parâmetros a serem configurados.

3.2.1 Banco de Dados da Curva Colina

O primeiro passo no processo de ajuste dos pontos da CET consiste na extração dos dados presentes no gráfico fornecido pelo fabricante da turbina. A Figura 15 exhibe as amostras extraídas da CET da UHE estudada. Algumas observações podem ser feitas sobre CETs de modo geral: (i) a superfície é não linear; (ii) embora algumas regiões possuam alta concentração de dados, outras apresentam consideráveis vazios, o que pode ser observado na Figura 15; (iii) os pontos não são caoticamente espalhados sobre o espaço, sendo na verdade dispostos como linhas relativamente bem comportadas.

Figura 15 – Amostras da CET plotadas (a) em 2 dimensões e (b) em 3 dimensões



Fonte: Elaborada pelo autor (2019).

As curvas A, B, C e D, apresentadas na Figura 15(a), são os Limites de Cavitação, sendo que B diz respeito ao período dentro da garantia da turbina e D para depois da garantia. Todas as CETs possuem Limites de Cavitação, os quais delimitam as chamadas zonas proibitivas de operação. Como a operação além destes limites severamente compromete a vida útil das turbinas, tal operação é evitada sempre que possível. Portanto, caso o ajuste da CET gere distorções além dos Limites de Cavitação, estas possuirão pequena ou até mesmo nenhuma relevância.

Levando em consideração a abordagem proposta para o problema, os pontos da CET foram ajustados por diversos métodos. Os erros relativos médio (e_{med}) e máximo (e_{max}) foram comparados entre os métodos para que avaliações pudessem ser efetuadas. Como uma etapa crucial deste processo, cada superfície gerada foi analisada, já que distorções indesejadas podem ocorrer, o que se tornará claro adiante.

3.2.2 Métodos de Ajuste

É comum que artigos sobre otimização de UHEs não discurssem sobre o tratamento dado à CET da UHE estudada. Este assunto é frequentemente ignorado, o que provavelmente se deve à tradição de se utilizar polinômios para ajustar os dados da CET.

A seguir, diferentes metodologias utilizadas para ajustar uma CET real são descritas. Ambas as técnicas ANFIS e ELANFIS foram testadas considerando e não considerando a clusterização de dados. Além disso, ajustes polinomiais também foram avaliados.

Em um primeiro momento, considera-se métodos de ajuste aplicados a todos os pontos da CET simultaneamente, ou seja, independentemente do método, apenas uma função / “caixa preta” foi criada para fornecer a eficiência para quaisquer valores de altura de queda líquida e vazão. Como vantagem, o uso de um único ajuste garante que nenhuma distorção ou descontinuidade seja provocada na superfície gerada. No entanto, pode ser uma tarefa árdua ajustar todos os dados simultaneamente e assegurar erros baixos.

Como um método mais simples, polinômios foram testados. É importante destacar que usar um único polinômio para obter a superfície definitiva não é aconselhável em problemas reais, ao menos no que diz respeito especificamente a curvas de eficiências de turbinas, pois, como concluído empiricamente neste trabalho e mencionado em (24), tal medida gera erros expressivos em comparação a métodos alternativos. Neste trabalho, esta abordagem foi aplicada apenas para fins de comparação.

Muitas são as aplicações da arquitetura ANFIS em várias áreas de pesquisa. Neste trabalho, essa técnica foi aplicada ao problema de ajuste de uma CET e seus resultados foram analisados. Os parâmetros N_{FP} e N_E foram variados para que suas influências na superfície gerada e nos erros obtidos fossem verificados. O método ELANFIS, que é uma combinação de ELM e ANFIS, também foi aplicado ao problema e os mesmos procedimentos descritos para a aplicação do ANFIS foram realizados.

Uma maneira comum e eficiente de reduzir erros em qualquer ajuste de curva é dividir os dados em clusters e ajustar cada cluster separadamente. Independentemente do método usado, quanto menor o número de amostras de dados, mais fácil tende a ser o ajuste, desde que os dados sejam agrupados adequadamente.

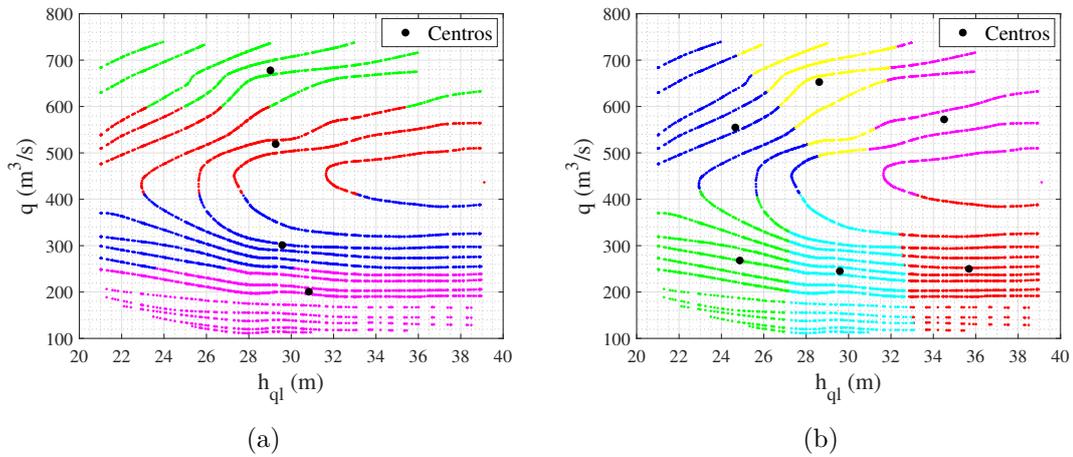
Muitos métodos de agrupamento podem ser encontrados na literatura (vide quarto parágrafo da Seção 3.2). A respeito destes, muitos são os princípios matemáticos que os originam. Por exemplo, os expostos no início deste capítulo são baseados no SF e foram inspirados no algoritmo FCM. Este associa cada amostra do banco de dados a um valor de pertinência (VP) entre 0 e 1 para cada cluster, minimizando uma função objetivo baseada nas distâncias dos centros dos clusters às amostras. A soma dos VPs é igual a 1 para cada amostra, o que significa que uma amostra específica não pertence exclusivamente a um cluster. Na verdade, tal amostra pertence a todos os clusters, porém com diferentes relevâncias. Cada cluster possui um centro, para o qual é possível calcular a distância até uma amostra que não foi usada no processo de clusterização e, ao fazer tal procedimento, determinar com qual cluster essa amostra se relaciona mais. Neste trabalho, esta etapa é essencial para obter o valor de eficiência das turbinas para amostras que não fazem parte do conjunto de dados original.

É importante mencionar que o algoritmo FCM utiliza um parâmetro de imprecisão para determinar quão “nebulosas” são as variáveis. Neste trabalho, esse parâmetro foi considerado igual a dois. Tal valor foi atribuído empiricamente após uma série de testes em busca de resultados mais promissores.

O FCM pode ser executado considerando diferentes tipos de distância no espaço. Neste trabalho foram estudadas as distâncias Euclidiana (D_E) e de Mahalanobis (D_M). O número de clusters (N_C) foi variado de 2 a 12. A Figura 16 exemplifica algumas possibilidades de clusterização considerando os dois tipos de distância mencionados acima. Uma vez que o conjunto de dados foi agrupado, foram realizados testes com os diferentes métodos mencionados, ou seja, polinômios, ANFIS e ELANFIS.

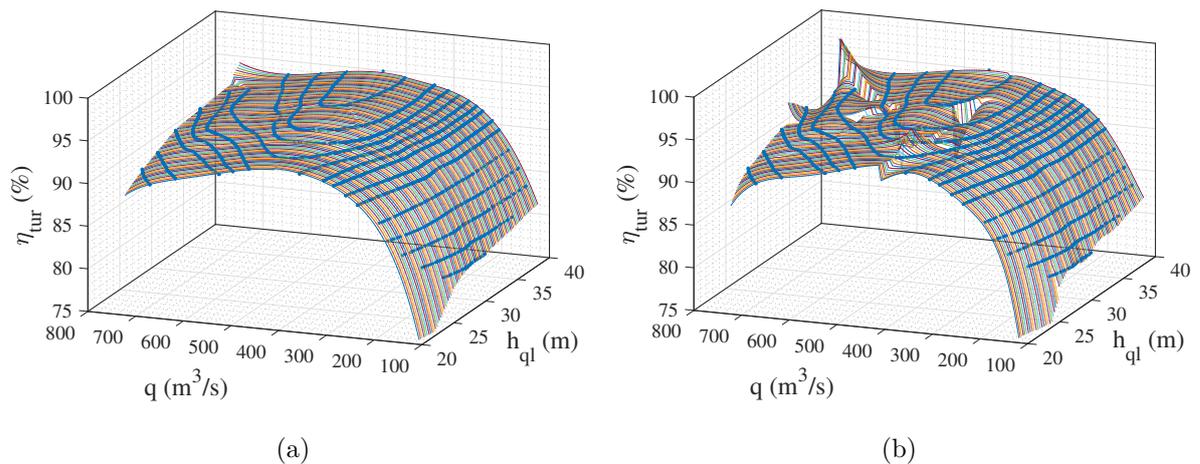
Uma etapa importante na clusterização de dados visando o ajuste de curvas é a sobreposição dos clusters. No FCM, o fato de todas amostras pertencerem a todos os clusters com diferentes relevâncias é de grande utilidade para se estabelecer sobreposição. Neste trabalho, se o VP mais alto de uma amostra for maior ou igual a 0,7, esta será considerada fortemente pertencente ao cluster correspondente e somente a este cluster será associada. Se o parâmetro mencionado for menor que 0,7, a amostra será associada não apenas ao cluster com o qual mais se relaciona, mas também ao cluster para o qual possui o segundo VP mais alto. Por fim, se o terceiro VP mais alto for maior que 0,1, a amostra também será associada ao cluster correspondente a este VP. A Figura 17 esclarece que usar dados não sobrepostos não é adequado, pois tal abordagem compromete severamente a integridade da superfície gerada.

Figura 16 – Clusterização da CET com (a) D_E e $N_C = 4$ e (b) D_M e $N_C = 6$



Fonte: Elaborada pelo autor (2019).

Figura 17 – Ajuste polinomial (grau 5, 9 clusters D_M) (a) com e (b) sem sobreposição



Fonte: Elaborada pelo autor (2019).

3.2.3 Resultados

Esta seção apresenta as análises e tabelas de erros para todas as abordagens expostas previamente. Em todas as tabelas apresentadas, os valores marcados com um asterisco correspondem a superfícies geradas consideradas viáveis. Todas as simulações foram realizadas na versão 2016a do software MATLAB[®]. Os ajustes polinomiais e por ANFIS foram executados através dos comandos “fit” e “ANFIS” do MATLAB[®]. Os códigos do ELANFIS em linguagem MATLAB[®] podem ser encontrados em <https://www.pushpakjagtap.com/tool/extremeanfisc/>.

Tanto para dados não clusterizados quanto para clusterizados, foram testados polinômios de grau 2, 3, 4 e 5. Para dados não clusterizados ajustados por ANFIS e

ELANFIS, N_{FP} foi inicialmente variado de 2 a 10, considerando várias possibilidades de N_E . Para dados clusterizados ajustados por ANFIS e ELANFIS, variou-se N_{FP} de 2 a 6 com o valor único igual a 1000 para N_E devido ao grande esforço computacional associado às simulações.

A Tabela 3 lista os erros para os ajustes polinomiais únicos. Conforme mencionado anteriormente, este método tem o único objetivo de fornecer comparações.

Tabela 3 – Erros no ajuste via polinômio único

Grau	2	3	4	5
e_{med}	0,9284*	0,3593*	0,1869*	0,1424*
e_{max}	6,7748*	3,0345*	1,7616*	1,3786*

Fonte: Elaborada pelo autor (2019).

A Tabela 4 lista os erros do ajuste único por ANFIS e revela que o aumento de N_{FP} e N_E resultou em uma tendência geral, com poucas exceções, de reduzir e_{med} , enquanto que e_{max} apresentou esta mesma tendência, embora com menos consistência.

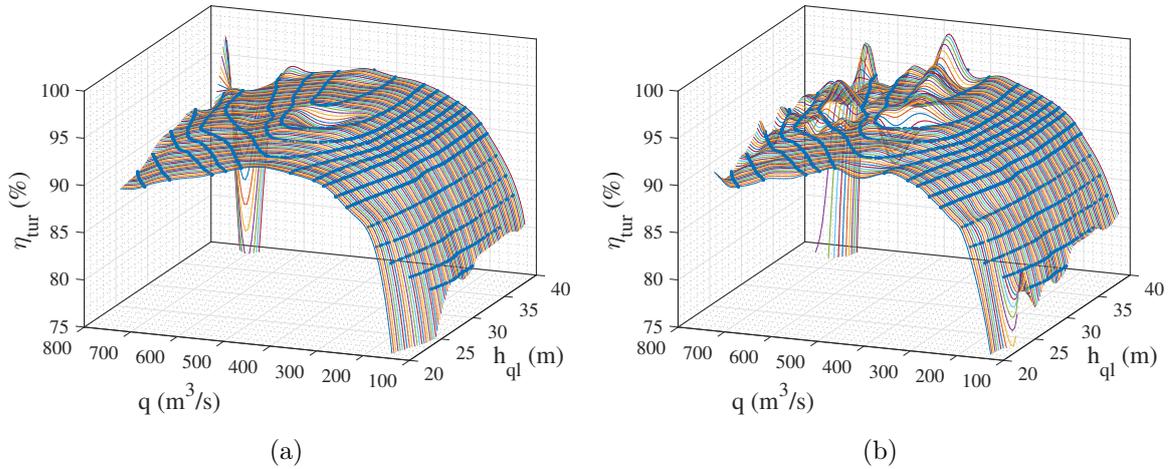
Tabela 4 – Erros no ajuste via ANFIS único

	$N_E = 100$		$N_E = 200$		$N_E = 500$		$N_E = 1000$	
N_{FP}	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}
2	0,1682*	1,8563*	0,1467*	2,0038*	0,1447*	2,0325*	0,1447*	2,0324*
3	0,1416*	1,4162*	0,1205*	1,3049*	0,1062*	1,2632*	0,1053*	1,2652*
4	0,1464*	2,0095*	0,1377*	1,9567*	0,1328*	1,9273*	0,1326*	1,9232*
5	0,0865	1,3913	0,0844	1,3750	0,0833	1,3655	0,0833	1,3654
6	0,0943*	1,1985*	0,0869*	1,2096*	0,0573	1,0856	0,0567	1,0690
7	0,0504	0,8106	0,0405	0,6441	0,0393	0,6188	0,0389	0,6050
8	0,0533	1,0608	0,0517	1,0313	0,0508	1,0116	0,0507	1,0102
9	0,0410	0,9386	0,0317	1,1426	0,0263	0,9723	0,0296	0,7332
10	0,0306	0,8637	0,0247	0,9017	0,0245	0,8854	0,0244	0,8837

Fonte: Elaborada pelo autor (2019).

Para N_{FP} de 3 a 10, as superfícies geradas apresentaram distorções mais expressivas além dos Limites de Cavitação quanto maior foi o valor de N_{FP} . No entanto, conforme mencionado na subseção 3.2.1, tais distorções não são relevantes. Para N_{FP} igual a 5, todas as superfícies geradas apresentaram uma distorção menor, embora comprometedoras. Para N_{FP} igual a 6, as superfícies geradas são viáveis para N_E iguais a 100 e 200. No entanto, apresentavam distorções menores, embora comprometedoras, para N_E iguais para 500 e 1000. Para N_{FP} de 7 a 10, as superfícies geradas apresentaram distorções mais graves quanto maior o valor de N_{FP} para todos os N_E , como exemplificado na Figura 18.

Figura 18 – Superfícies via ANFIS único com $N_E = 1000$ e $N_{FP} =$ (a) 7 e (b) 10



Fonte: Elaborada pelo autor (2019).

Outras redes com N_E mais elevados foram treinadas para N_{FP} de 2 a 6 visando verificar a influência deste parâmetro nos erros e também nas superfícies geradas via aplicação dos valores 5 e 6 para N_{FP} . Tal experimento não afetou a integridade das superfícies geradas para N_{FP} igual a 2 a 4. Para N_{FP} igual a 5 e 6, as distorções menores permaneceram, mesmo com valores mais elevados de N_E . A Tabela 5 lista os erros e expõe o fato de que o aumento do N_E resultou em uma redução consistente, porém pequena, ou mesmo nula, em seus valores.

Quanto ao ajuste único via ELANFIS, a Tabela 6 lista os erros e revela que o aumento de N_{FP} muitas vezes resultou em e_{med} mais baixos, enquanto que os valores de e_{max} , apesar de se comportarem de maneira inconsistente, apresentaram tendência a serem reduzidos. Aumentar o N_E reduziu e_{med} em muitos casos. No entanto, este aumento afetou e_{max} de uma maneira altamente imprevisível. As superfícies geradas fornecidas pelo ELANFIS demonstraram não ter um padrão sólido em relação à sua viabilidade de acordo com aumentos no N_E .

Distorções além dos Limites de Cavitação apareceram pela primeira vez com N_{FP} igual a 4 e outras ocorrências se mostraram imprevisíveis. Para N_{FP} igual a 5 e de 7 a 10, as superfícies geradas foram inviáveis para todo valor de N_E .

Mais redes com valores mais elevados de N_E foram treinadas para N_{FP} de 2 a 6, para que esse parâmetro pudesse ser investigado mais detalhadamente. A Tabela 7 lista os erros e mostra que as inconsistências em relação aos e_{max} e à viabilidade da superfície gerada permaneceram.

Com relação ao ajuste de dados com clusterização, os ajustes polinomiais, via ANFIS e via ELANFIS serão a partir de agora referidos como FCM-P, FCM-ANFIS e FCM-ELANFIS, respectivamente.

Tabela 5 – Erros no ajuste via ANFIS único com valores mais altos de N_E

	$N_{FP} = 2$		$N_{FP} = 3$		$N_{FP} = 4$	
N_E	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}
1500	0,1447*	2,0320*	0,1052*	1,2619*	0,1327*	1,9257*
2000	0,1447*	2,0316*	0,1051*	1,2592*	0,1326*	1,9258*
2500	0,1447*	2,0312*	0,1049*	1,2550*	0,1326*	1,9258*
3000	0,1446*	2,0308*	0,1049*	1,2535*	0,1326*	1,9235*
3500	0,1446*	2,0304*	0,1048*	1,2508*	0,1326*	1,9235*
4000	0,1446*	2,0300*	0,1047*	1,2468*	0,1326*	1,9235*
4500	0,1446*	2,0296*	0,1046*	1,2451*	0,1326*	1,9235*
5000	0,1446*	2,0292*	0,1045*	1,2422*	0,1326*	1,9235*
5500	0,1446*	2,0288*	0,1045*	1,2383*	0,1326*	1,9235*
6000	0,1445*	2,0284*	0,1044*	1,2364*	0,1326*	1,9235*

	$N_{FP} = 5$		$N_{FP} = 6$		-	-
N_E	e_{med}	e_{max}	e_{med}	e_{max}	-	-
1500	0,0833	1,3662	0,0567	1,0690	-	-
2000	0,0833	1,3662	0,0567	1,0690	-	-
2500	0,0833	1,3662	0,0567	1,0690	-	-
3000	0,0833	1,3661	0,0567	1,0690	-	-
3500	0,0833	1,3662	0,0567	1,0690	-	-
4000	0,0833	1,3662	0,0567	1,0690	-	-
4500	0,0833	1,3662	0,0567	1,0690	-	-
5000	0,0833	1,3662	0,0567	1,0690	-	-
5500	0,0833	1,3662	0,0567	1,0690	-	-
6000	0,0833	1,3662	0,0567	1,0690	-	-

Fonte: Elaborada pelo autor (2019).

Tabela 6 – Erros no ajuste via ELANFIS único

	$N_E = 100$		$N_E = 200$		$N_E = 500$		$N_E = 1000$	
N_{FP}	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}
2	0,1839*	1,3024*	0,1324*	1,4819*	0,1558*	1,4239*	0,1477*	1,5088*
3	0,1086	0,9526	0,1039*	1,2575*	0,0908*	1,1921*	0,0988*	1,3460*
4	0,0860*	1,1879*	0,0893*	1,0962*	0,0922	1,6173	0,0866*	1,0716*
5	0,0725	1,1006	0,0805	0,9177	0,0718	1,1557	0,0663	0,8852
6	0,0669	0,9132	0,0677	1,0203	0,0554	1,1251	0,0529*	0,9825*
7	0,0526	0,8969	0,0480	0,8196	0,0485	0,8999	0,0495	0,8951
8	0,0413	0,9415	0,0387	0,5812	0,0458	0,7956	0,0449	0,6279
9	0,0429	0,6799	0,0410	0,6697	0,0319	0,7821	0,0305	0,7939
10	0,0345	0,5449	0,0279	1,0356	0,0253	0,6316	0,0286	0,7204

Fonte: Elaborada pelo autor (2019).

Tabela 7 – Erros no ajuste via ELANFIS único com valores mais altos de N_E

	$N_{FP} = 2$		$N_{FP} = 3$		$N_{FP} = 4$	
N_E	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}
1500	0,1425*	1,3623*	0,0959*	1,4838*	0,0865*	1,0540*
2000	0,1387*	1,4979*	0,0986*	0,9556*	0,0792*	0,9092*
2500	0,1384*	1,4261*	0,0966*	1,0299*	0,0828*	1,0434*
3000	0,1495*	1,3680*	0,1017*	0,8676*	0,0845	0,8909
3500	0,1429*	1,5065*	0,0930*	1,0608*	0,0836*	0,8248*
4000	0,1318*	1,3878*	0,0970*	1,3602*	0,0824*	1,1961*
4500	0,1390*	1,3853*	0,0983*	0,8654*	0,0826*	0,7560*
5000	0,1326*	1,3687*	0,0937	0,9997	0,0800*	1,1441*
5500	0,1365*	1,3516*	0,0968*	1,0401*	0,0744*	1,3293*
6000	0,1406*	1,3813*	0,0947*	1,1437*	0,0708*	1,4184*
	$N_{FP} = 5$		$N_{FP} = 6$		-	-
N_E	e_{med}	e_{max}	e_{med}	e_{max}	-	-
1500	0,0706*	0,9568*	0,0549	0,9488	-	-
2000	0,0609*	1,2264*	0,0583	0,7468	-	-
2500	0,0617	1,1984	0,0568	0,7321	-	-
3000	0,0678	0,9294	0,0532	0,7868	-	-
3500	0,0691*	0,8786*	0,0609	0,8644	-	-
4000	0,0747*	0,8540*	0,0501	1,1796	-	-
4500	0,0612*	1,2048*	0,0508	1,0469	-	-
5000	0,0629	0,9722	0,0599	0,6500	-	-
5500	0,0647*	1,0999*	0,0574*	0,7807*	-	-
6000	0,0697*	0,9423*	0,0554*	0,9484*	-	-

Fonte: Elaborada pelo autor (2019).

A Tabela 8 lista os erros dos polinômios de grau 5. Como os graus 2 a 4 apresentaram desempenho geral inferior, seus erros não foram expostos. Embora a maioria dos casos tenham concedido superfícies geradas inviáveis, a utilização da D_E forneceu uma quantidade maior de superfícies geradas que a utilização da D_M para os polinômios de grau 2 a 4. O oposto é verdadeiro para o grau 5. Distorções além dos Limites de Cavitação ocorreram apenas nos ajustes com graus 4 e 5 e mais frequentemente nos casos com D_E . O aumento de N_C resultou na redução de erros em quase todos os casos. No entanto, em muitos casos, causou descontinuidades críticas nas superfícies geradas devido a regiões no espaço que carecem consideravelmente de amostras, como visto entre os níveis de 94,5% e os 95% de eficiência na Figura 15(a).

Como a aplicação de valores de 7 a 10 para N_{FP} causou distorções nas superfícies geradas no ajuste único via ANFIS, optou-se por atribuir N_{FP} de 2 a 6 no ajuste via FCM-ANFIS. Utilizou-se N_E igual a 1000, pois aumentos além deste valor neste parâmetro resultaram em reduções irrelevantes dos erros na abordagem com ANFIS único

Tabela 8 – Erros no ajuste via polinômios de 5° grau com clusterização

N_C	D_E		D_M		N_C	D_E		D_M	
	e_{med}	e_{max}	e_{med}	e_{max}		e_{med}	e_{max}	e_{med}	e_{max}
2	0,0932	1,3228	0,1122*	1,3374*	8	0,0668	1,1395	0,0823	1,1876
3	0,1107	1,3398	0,1249*	1,3660*	9	0,0653	1,1395	0,0817*	1,0701*
4	0,0875	1,3418	0,1153	1,5295	10	0,0598	1,1950	0,0767	0,9446
5	0,0783	1,1398	0,0989*	1,3653*	11	0,0560	0,8996	0,0737	1,1881
6	0,0757	1,1836	0,0929*	1,2059*	12	0,0523	0,9160	0,0691	1,1011
7	0,0690*	1,1395*	0,0877	1,1392	-	-	-	-	-

Fonte: Elaborada pelo autor (2019).

(Tabela 5). Além disso, valores mais elevados deste parâmetro implicaram em durações significativamente extensas das simulações. É importante mencionar que, caso se verifique que este método se mostra promissor ou superior aos outros em um problema específico, experimentos adicionais aplicando diferentes valores de N_E podem ser realizados para que a influência deste parâmetro nos erros e na integridade da superfície gerada seja analisada. A Tabela 9 lista os erros desta abordagem. Para N_{FP} de 4 a 6, todas as superfícies geradas apresentaram desde distorções pequenas a muito graves, porém sempre comprometedoras. Portanto, decidiu-se não expor os erros destes casos. Uma tendência geral à redução de erros pode ser observada na Tabela 9 com N_{FP} e N_C mais elevados, embora não tão consistentemente se tratando de e_{max} . Como no FCM-P, e pelo mesmo motivo, alguns casos com elevado N_C sofreram descontinuidades críticas.

Tabela 9 – Erros no ajuste via ANFIS com clusterização

N_C	D_E				D_M			
	$N_{FP} = 2$		$N_{FP} = 3$		$N_{FP} = 2$		$N_{FP} = 3$	
	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}
2	0,1112	1,4796	0,0605*	1,2781*	0,1488	1,8015	0,0878*	1,1311*
3	0,1174	1,4541	0,0713*	1,2661*	0,1530	2,0317	0,1007*	1,2803*
4	0,0945	1,3997	0,0590	1,2896	0,1316*	1,6934*	0,0827	1,4107
5	0,0786	1,1004	0,0414	0,4156	0,1206	1,2438	0,0741*	1,0033*
6	0,0705*	1,2687*	0,0494	0,7858	0,1168	1,3024	0,0605	0,8934
7	0,0599*	1,1029*	0,0338	0,4374	0,0997	1,2555	0,0583	0,9459
8	0,0580*	1,1032*	0,0321	0,4450	0,0962	1,2095	0,0500	0,9815
9	0,0558*	1,1003*	0,0307	0,4295	0,0853*	1,0992*	0,0537	0,7700
10	0,0493	1,0221	0,0246	0,4342	0,0884	1,1128	0,0454	0,8263
11	0,0519*	0,9081*	0,0235	0,7743	0,0836	1,4128	0,0440	1,1380
12	0,0459	0,7498	0,0199	0,7741	0,0751	1,5885	0,0410	1,0325

Fonte: Elaborada pelo autor (2019).

Analogamente ao FCM-ANFIS, testou-se apenas valores de 2 a 6 para N_{FP} no FCM-ELANFIS. Como alterações em N_E foram inconclusivas no ELANFIS único, utilizou-se N_E igual a 1000 (condições iguais aos casos via FCM-ANFIS). A Tabela 10 lista os erros desta abordagem. Todas as superfícies foram inviáveis para N_{FP} de 4 a 6, logo, seus erros foram suprimidos. Assim como no FCM-ANFIS, N_{FP} e N_C mais altos forneceram erros menores e com menos consistência para e_{max} ; casos com N_C mais elevados sofreram descontinuidades críticas pelos mesmos motivos expostos no ajuste via FCM-ANFIS.

Tabela 10 – Erros no ajuste via ELANFIS com clusterização

	D_E				D_M			
	$N_{FP} = 2$		$N_{FP} = 3$		$N_{FP} = 2$		$N_{FP} = 3$	
N_C	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}	e_{med}	e_{max}
2	0,1038	1,1615	0,0651	1,2644	0,1250*	1,5916*	0,0811*	1,3376*
3	0,1211	1,2780	0,0829	1,4306	0,1446	1,5928	0,0889	0,8613
4	0,0876	1,2250	0,0704	0,9977	0,1196	1,4398	0,0826	0,9787
5	0,0885	1,1290	0,0492	1,0960	0,1051	1,3923	0,0732*	0,9006*
6	0,0734*	1,3036*	0,0494*	0,9448*	0,1043	1,1810	0,0681*	1,2406*
7	0,0724*	1,2117*	0,0428	1,2576	0,0900	1,5013	0,0573	0,9034
8	0,0687*	1,3032*	0,0408	0,7293	0,0857	1,2236	0,0586	0,8946
9	0,0682	1,2610	0,0424	0,8936	0,0763	1,5605	0,0500	1,0002
10	0,0634	1,2214	0,0340	1,0506	0,0752	1,0067	0,0432	1,0282
11	0,0602	0,7119	0,0308	0,7263	0,0763	1,2684	0,0498	0,8925
12	0,0513	1,0007	0,0267	0,6665	0,0664	1,2290	0,0436	0,7377

Fonte: Elaborada pelo autor (2019).

A Tabela 11 lista os erros dos melhores casos viáveis de cada método. Ajustes únicos polinomiais garantiram superfícies contínuas, mas com erros mais expressivos. O ajuste via ANFIS único concedeu boas superfícies em condições adequadas e reduziu os erros em comparação aos polinômios únicos. Embora a viabilidade das superfícies obtidas via ELANFIS único tenha sido imprevisível com a variação de N_E , este método forneceu uma superfície gerada viável e superior à melhor fornecida pelo ANFIS único.

Nos ajustes de dados clusterizados, embora a maioria das superfícies tenham sido inviáveis, o melhor caso viável de cada método se mostrou superior ao melhor ajuste único do respectivo método – incluindo os polinômios de grau 2, 3 e 4. Os ajustes únicos via ANFIS e ELANFIS forneceram superfícies viáveis para N_{FP} de 4 a 6, ao contrário de suas versões com clusterização, o que indica que N_{FP} mais elevados requerem mais amostras para garantir superfícies satisfatórias. Percebeu-se que a utilização da D_E concedeu melhores ajustes em relação aos erros e também à integridade das superfícies.

No ajuste de CETs, distorções além dos limites de cavitação são irrelevantes. Se tal fato fosse desconsiderado e toda a curva exigisse um ajuste bem comportado, alguns

Tabela 11 – Erros nos melhores casos de cada abordagem

Método	Parâmetros	e_{med}	e_{max}
Polinômio único	Grau 5	0,1424	1,3786
ANFIS único	$N_{FP} = 6; N_E = 200$	0,0869	1,2096
ELANFIS único	$N_{FP} = 6; N_E = 1000$	0,0529	0,9825
FCM-P	$N_C = 7; D_E$; Grau 5	0,0690	1,1395
FCM-ANFIS	$N_C = 11; D_E; N_{FP} = 2$	0,0519	0,9081
FCM-ELANFIS	$N_C = 6; D_E; N_{FP} = 3$	0,0494	0,9448

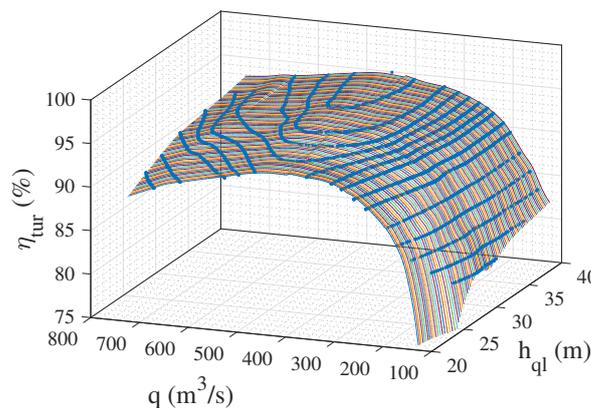
Fonte: Elaborada pelo autor (2019).

dos melhores casos não seriam os da Tabela 11. A Tabela 12 lista os erros dos melhores casos dos métodos afetados neste contexto. Porém, o ajuste via ELANFIS com $N_{FP} = 3$ e 6 clusters baseados na D_E permaneceu superior. Esta rede, cuja superfície se encontra na Figura 19, foi escolhida como a definitiva para modelar a CET nas simulações.

Tabela 12 – Erros nos melhores casos considerando toda a superfície gerada

Método	Parâmetros	e_{med}	e_{max}
ANFIS único	$N_{FP} = 3; N_E = 6000$	0,1044	1,2364
ELANFIS único	$N_{FP} = 6; N_E = 6000$	0,0554	0,9484
FCM-P	$N_C = 6; D_M$; Grau 5	0,0929	1,2059

Fonte: Elaborada pelo autor (2019).

Figura 19 – Melhor ajuste obtido: FCM-ELANFIS com $N_C = 6$, D_E e $N_{FP} = 3$ 

Fonte: Elaborada pelo autor (2019).

Com todos os aspectos pertinentes da UHE modelados e estabelecida a formulação para otimização, o capítulo seguinte discute as aplicações das metodologias apresentadas.

4 ESTUDOS DE CASO

A UHE estudada pertence ao grupo EDP do Brasil, uma filial da companhia Portuguesa EDP (Energias de Portugal) e faz parte de um conjunto de usinas em cascata.

Em Abril de 2019, iniciou-se um projeto de P&D da ANEEL em parceria com a UFJF para otimizar a operação diária de tal usina. Foi realizada uma vasta revisão da literatura de modo a se encontrar a formulação que melhor se enquadraria nas características da UHE. Além disso, foram testadas diferentes metodologias para a resolução do problema. As próximas seções se dedicam a expor as análises realizadas com base na formulação utilizada e também os resultados oriundos das aplicações das TICs como metodologia de resolução. Uma série de características da UHE estudada são expostas na Tabela 13.

4.1 EXPANSÃO DO MODELO DE USINA HIDRELÉTRICA

Como detalhado na seção 3.1, utilizou-se a formulação proposta em (21; 23) para modelar a UHE. Todavia, ao longo dos estudos percebeu-se que existiam situações em que a solução ótima não fornecia a menor vazão turbinada em relação à outras soluções, ou seja, quando comparando duas ou mais soluções distintas, ocasionalmente a solução que proporcionava a menor quantidade de perdas de potência resultava em turbinamentos maiores que outras soluções. Dado o contexto do projeto de minimizar o uso dos recursos hídricos, modificações na formulação original se tornaram necessárias.

Para que se alcançasse o objetivo estabelecido, o Algoritmo 4 foi alterado de forma a gerar funções de vazão turbinada além de funções de perdas. Para tal, no passo 1.a)vii. do Algoritmo 4 armazena-se o valor da vazão turbinada total (q_{tot}) além das perdas totais (per_{tot}) e geração ($p_{g_{tot}}$). Este procedimento permite que seja obtido, para cada valor possível de quantidade de máquinas (n), um vetor de vazão turbinada em função da geração da usina.

Com o intuito de analisar a relação entre perdas e vazões, plotou-se simultaneamente as funções normalizadas de perdas e de vazões para os casos de quatro e cinco unidades geradoras. A Figura 20 exibe este gráfico e permite que as seguintes afirmações sejam feitas em relação ao intervalo em comum de geração com quatro ou cinco unidades geradoras:

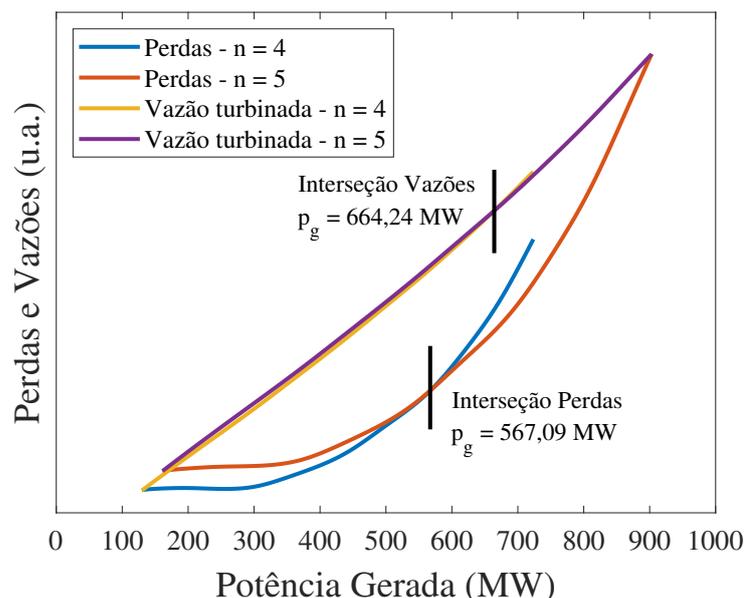
- Se $p_{g_{tot}} < 567,09$ MW, a operação com quatro unidades geradoras proporciona menos perdas e menor vazão;
- Se $p_{g_{tot}} > 664,24$ MW, a operação com cinco unidades geradoras proporciona menos perdas e menor vazão;
- Se $567,09 < p_{g_{tot}} < 664,24$, a operação com cinco unidades geradoras proporciona menos perdas, porém maior vazão.

Tabela 13 – Características da UHE estudada

Dados Hidrometeorológicos	
Área de drenagem	184219 hm ²
Vazão média	2532 m ³ /s
Vazão máxima registrada (24/02/80)	28558 m ³ /s
Vazão mínima registrada (19/10/94)	263 m ³ /s
Reservatório	
Nível da água montante operacional normal	212 m
Nível da água montante máximo	212,6 m
Nível da água jusante máximo normal	187,2 m
Nível da água jusante máximo excepcional	201,5 m
Área do nível da água normal	630 km ²
Volume do nível da água normal	5,19 · 10 ⁹ m ³
Vida útil prevista	100 anos
Energia firme	504 MW médios
Energia média anual	566 MW médios
Energia Assegurada:	526,6 MW médios
Extensão	170 km
Profundidade média	8 m
Barramento	
Comprimento total	2034,43 m
Altura Máxima	74 m
Cota de crista	215 m
Vertedouro	
Número de vãos	14
Comportas	17 m x 23,3 m
Vazão de desvio	26160 m ³
Vazão do projeto	498701 m ³
Unidades Geradoras	
Potência nominal de cada unidade	180,5 MW
Vazão nominal de cada unidade	700 m ³
Queda líquida	29 m
Rotação	100 RPM
Potência nominal da usina	902,5 MW
Número de unidades	5
Tipo de turbina	Kaplan
Entrada em Operação	
Unidade geradora 1	01/12/2001
Unidade geradora 2	01/03/2002
Unidade geradora 3	09/05/2002
Unidade geradora 4	30/07/2002
Unidade geradora 5	07/11/2002

Fonte: <https://brasil.edp.com/pt-br/generation>.

Figura 20 – Funções normalizadas de perdas e vazões da UHE estudada



Fonte: Elaborada pelo autor (2019).

Estas afirmações provam que minimizar as perdas segunda a formulação original não é equivalente à minimizar a vazão turbinada, pois existem situações em que a operação garante perdas mínimas, porém consome mais água. Por exemplo, ao se gerar 600 MW visando a minimização de perdas, cinco unidades geradoras seriam ligadas. No entanto, a utilização mínima de recursos ocorre operando-se com quatro unidades geradoras.

Para provar que algo é falso, basta obter um caso que viole a hipótese. Ou seja, não há necessidade de avaliar as funções de uma, duas ou três unidades, visto que a análise oriunda da Figura 20 exhibe um caso que contradiz a ideia de que minimizar as perdas de potência enunciadas em (21; 23) equivale a minimizar o turbinamento.

Levando em consideração os fatores apresentados nesta seção, o código desenvolvido para a otimização da operação diária da UHE estudada foi implementado de modo que o operador pudesse escolher uma otimização baseada nas perdas de potência, como em (21; 23), ou nas vazões turbinadas, o que será discutido em detalhes na seção seguinte.

4.2 SIMULAÇÕES

Esta seção apresenta as aplicações dos métodos até então descritos. São fornecidos todos os dados utilizados, possibilitando assim reproduções dos resultados obtidos. Além disso, as técnicas de inteligência computacional aqui exploradas – SCA, GWO e ACO – são submetidas a uma série de simulações almejando a otimização da operação diária da usina sob estudo. Diversos resultados são analisados visando averiguar se aplicações das mesmas em situações reais são viáveis.

4.2.1 Dados de Entrada

Este trabalho relata aplicações de técnicas de inteligência computacional na otimização da operação de UHEs. Em relação às informações referentes ao modelo matemático da usina, os parâmetros a seguir foram extraídos do banco de dados do ONS: as Perdas Hidráulicas (h_{ph}), o Polinômio Vazão - Nível Jusante, o qual fornece o nível jusante (h_j), e o Nível do Reservatório (h_r), sendo este último registrado como um valor constante. A curva de eficiência das turbinas (CET), a qual contém os valores mínimo (q_{min}) e máximo (q_{max}) de turbinamento pelas unidades geradoras, e o número máximo de unidades geradoras (n_{ug}) foram recebidos da equipe de operação da UHE em questão. Dada a indisponibilidade de uma curva de eficiência dos geradores por parte da equipe de operação, aproximou-se um polinômio para este parâmetro (η_{ger}) a partir de valores típicos do mesmo, baseando-se também na potência nominal de 180,05 MW das unidades geradoras.

Em relação aos dados necessários para a otimização, o valor monetário de 1 MWh (c_{per}) é obtido diretamente do valor de mercado, portanto é uma informação que deve ser atualizada de acordo com a necessidade. O custo de uma partida ou parada (c_{pp}) é estimado a partir de detalhados estudos da usina. Como não fez parte do escopo do projeto a realização de tais estudos, adotou-se um valor somente para fins de simulação, embora este seja baseado na potência nominal e nas instruções contidas em (111; 112), os quais fornecem procedimentos gerais para estimativas do custo de partidas e paradas de máquinas. Outra informação importante é o número de unidades geradoras em operação no período imediatamente anterior ao primeiro período do horizonte de programação a ser otimizado (n_0), visto que com este valor, possibilita-se a contabilização dos custos de partidas ou paradas de unidades geradoras no primeiro período, caso ocorram.

Conforme explicado no Capítulo 3, a utilização de um valor constante para h_r é justificada pelo fato de se tratar da programação diária de uma UHE com reservatório significativamente extenso, ou seja, as variações no nível montante são desprezíveis em intervalos tão breves de tempo. Além disso, o fato de a UHE ser operada a fio d'água colabora para tal simplificação.

Com exceção da CET, a qual teve seu modelo estabelecido conforme apresentado na Seção 3.2, as informações não polinomiais mencionadas encontram-se expostas na Tabela 14, em que g e σ representam a aceleração da gravidade e a densidade da água do reservatório, respectivamente. Os polinômios para cálculo da eficiência dos geradores (η_{ger}) e do nível jusante (h_j) são descritos pelas Equações 4.1 e 4.2, respectivamente, estando os valores de seus coeficientes exibidos nas Tabelas 15 e 16, respectivamente. A reprodução do modelo da CET pode ser realizada conforme instruções contidas no Apêndice A.

$$\eta_{ger}(p_g) = g_3 \cdot p_g^3 + g_2 \cdot p_g^2 + g_1 \cdot p_g + g_0 \quad (4.1)$$

$$h_j(Q) = j_4 \cdot Q^4 + j_3 \cdot Q^3 + j_2 \cdot Q^2 + j_1 \cdot Q + j_0 \quad (4.2)$$

Tabela 14 – Dados parciais para simulações

Par.	Valor	Par.	Valor
g	$9,8 \text{ m/s}^2$	σ	997 kg/m^3
q_{min}	$111,21 \text{ m}^3/s$	q_{max}	$700 \text{ m}^3/s$
h_r	212 m	h_{ph}	$0,699999988079071 \text{ m}$
n_{ug}	5	n_0	0
c_{per}	50 u.a./MWh	c_{pp}	500 u.a.

Fonte: Elaborada pelo autor (2019).

Tabela 15 – Coeficientes da Equação 4.1

Parâmetro	Valor
g_3	$1,16413 \cdot 10^{-8}$
g_2	$-6,54716 \cdot 10^{-6}$
g_1	$1,26153 \cdot 10^{-3}$
g_0	$9,02377 \cdot 10^{-1}$

Fonte: Elaborada pelo autor (2019).

Tabela 16 – Coeficientes da Equação 4.2

Parâmetro	Valor
j_4	$-5,7384099896314700 \cdot 10^{-17}$
j_3	$4,4759001192884450 \cdot 10^{-12}$
j_2	$-1,3583199631739262 \cdot 10^{-7}$
j_1	$2,4155001156032085 \cdot 10^{-3}$
j_0	$1,7136599731445312 \cdot 10^2$

Fonte: Elaborada pelo autor (2019).

As metas de geração (d_t) consideradas na simulações, expostas na Tabela 17, na qual “Per.” denota o período, foram extraídas do histórico de operações da UHE estuda, ou seja, correspondem a valores realmente típicos da usina. De todos os dados disponibilizados, optou-se por selecionar o dia em que houve a maior variação das metas ao longo do horizonte de programação. Tal escolha visa aumentar o nível de dificuldade no processo de otimização e, portanto, torná-lo mais desafiador para as TICs. Recordar-se que o horizonte estudado é composto de 24 horas discretizadas de meia em meia hora, resultando assim em 48 períodos.

4.2.2 Obtenção das Funções de Perdas e Vazões

Inseridos os dados de entrada referentes à UHE estuda, aplicou-se o Algoritmo 4 levando-se em consideração a adaptação relatada na Seção 4.1, ou seja, foram armazenados

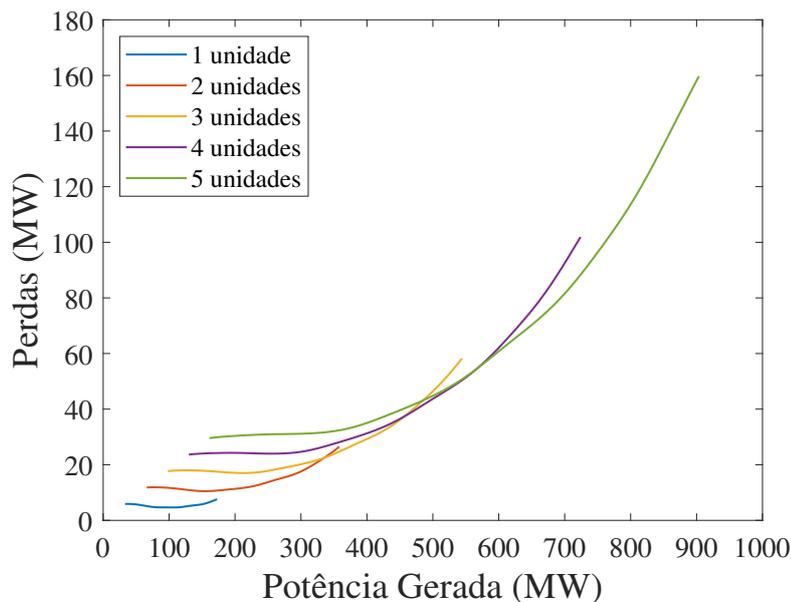
Tabela 17 – Metas de Geração

Per.	d_t (MW)						
1	650	13	300	25	850	37	650
2	650	14	300	26	850	38	650
3	650	15	300	27	850	39	650
4	650	16	300	28	850	40	650
5	400	17	300	29	850	41	650
6	300	18	650	30	850	42	650
7	300	19	650	31	850	43	650
8	300	20	650	32	850	44	650
9	300	21	650	33	850	45	650
10	300	22	850	34	850	46	650
11	300	23	850	35	850	47	650
12	300	24	850	36	650	48	650

Fonte: Elaborada pelo autor (2019).

valores de perdas de potência e de vazão turbinada total em função da geração da usina. As Figuras 21 e 22 exibem as funções de perdas e de vazões, respectivamente. Em ambas figuras é possível observar que as faixas de geração variam de acordo com o número de unidades geradoras em operação. Além disso, nota-se o comportamento quase linear da vazão turbinada pela UHE em função da geração.

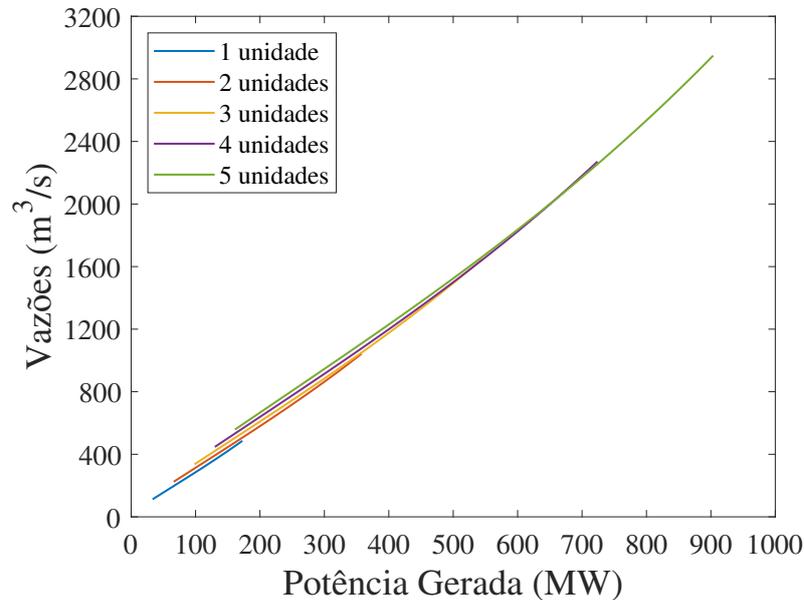
Figura 21 – Funções de perdas da UHE estuda



Fonte: Elaborada pelo autor (2019).

Foram também obtidos os vetores que descrevem as gerações mínimas (p_{min_n}) e máximas (p_{max_n}) para cada configuração de unidades geradoras, os quais encontram-se

Figura 22 – Funções de vazões da UHE estuda.



Fonte: Elaborada pelo autor (2019).

expostos na Tabela 18. É interessante notar que as capacidades de geração não crescem linearmente com o número de unidades acionadas, o que se deve às complexas relações entre turbinamento, altura de queda e potência gerada.

Tabela 18 – Gerações mínimas e máximas, em MW, para cada valor de n

n	1	2	3	4	5
p_{min_n}	33,2858	66,0312	98,2486	129,9497	161,1465
p_{max_n}	172,6942	358,0064	544,1636	723,9946	903,6151

Fonte: Elaborada pelo autor (2019).

As funções de perdas e de vazões são fundamentais para o sucesso do modelo de otimização empregado, visto que a função objetivo do problema (Equação 3.9) se baseia no número de partidas e paradas ocorridas durante o horizonte de programação e também nos valores de perdas ou vazões associadas ao atendimento das metas de geração estabelecidas pelo ONS.

4.2.3 Otimização da Operação

Para atingir o objetivo de relatar análises de técnicas de inteligência computacional aplicadas à otimização da operação diária de UHEs, aplicou-se duas TICs relativamente recentes na literatura e uma com vasta aplicação e renome. Estas são, respectivamente, o SCA, o GWO e o ACO.

Uma vez inseridos todos os dados de entrada e levantadas as funções de perdas e vazões da usina, torna-se possível efetuar a otimização da operação via Equações 3.9 a 3.11. Conforme descrito no Algoritmo 5, é possível determinar os limites inferiores ($n_{t_{min}}$) e superiores ($n_{t_{max}}$) das variáveis de decisão de acordo com as metas de geração e com os valores mínimos e máximos de geração para cada possibilidade de configuração, ou seja, para cada valor de unidades geradoras em operação. Os valores dos limites relacionados às metas exibidas na Tabela 17 encontram-se na Tabela 19. Uma vez obtidos os mencionados limites, independente de qual seja a TIC aplicada ao problema, torna-se possível manter as variáveis dentro da região viável ao se forçar que a mesma seja igual ao limite inferior ou ao superior caso a equação de atualização de posição da TIC retorne um valor menor que o primeiro ou maior que o segundo, respectivamente.

Tabela 19 – Limites inferiores e superiores

Per.	$n_{t_{min}}$	$n_{t_{max}}$	Per.	$n_{t_{min}}$	$n_{t_{max}}$	Per.	$n_{t_{min}}$	$n_{t_{max}}$
1	4	5	17	2	5	33	5	5
2	4	5	18	4	5	34	5	5
3	4	5	19	4	5	35	5	5
4	4	5	20	4	5	36	4	5
5	3	5	21	4	5	37	4	5
6	2	5	22	5	5	38	4	5
7	2	5	23	5	5	39	4	5
8	2	5	24	5	5	40	4	5
9	2	5	25	5	5	41	4	5
10	2	5	26	5	5	42	4	5
11	2	5	27	5	5	43	4	5
12	2	5	28	5	5	44	4	5
13	2	5	29	5	5	45	4	5
14	2	5	30	5	5	46	4	5
15	2	5	31	5	5	47	4	5
16	2	5	32	5	5	48	4	5

Fonte: Elaborada pelo autor (2019).

É comum que em problemas de otimização que características do mesmo sejam extraídas e utilizadas de modo a diminuir a complexidade do processo, como características mais diretas do sistema e comuns em problemas de otimização em geral, como os limites inferiores e superiores das variáveis de decisão. No entanto, inicialmente, com o intuito de aumentar o desafio e, portanto, possibilitar uma análise mais profunda dos desempenhos das TICs, a utilização dos limites foi alterada conforme descrito a seguir.

As aplicações dos limites para truncamento das variáveis dentro da região viável após a atualização das posições foram abandonadas em parte das simulações, denominada Conjunto de Simulações 1 (CS1), e aplicadas somente no Conjunto de Simulações 2 (CS2).

Como a usina em questão possui cinco unidades geradoras (n_{ug} em um caso genérico), estabeleceu-se como limites inferiores e superiores para truncamento os valores 1 e 5, respectivamente, independente da meta de geração. Sobre o limite inferior unitário, deve-se considerar a possibilidade de que, em certo período, zero unidades geradoras estejam em operação. É comum que a demanda seja nula em momentos específicos devido a fatores como, por exemplo, a realização de manutenções. Em tal ocorrência, a otimização em tais períodos não se faz necessária dada a modelagem do nível montante como um valor constante, bastando atribuir o valor nulo para a referida dimensão do indivíduo.

Para permitir que as TICs possam discernir soluções viáveis de inviáveis, aplicou-se uma penalização (pen) que utiliza o cálculo dos limites exibidos na Tabela 17 para incrementar a função objetivo proporcionalmente ao quanto a variável de decisão se desloca dos valores viáveis.

O cálculo de pen se dá via Algoritmo 6. A formulação de fato aplicada para avaliação das TICs é descrita pelas Equações 4.3 a 4.5 (recorda-se que c_{pp} , c_{per} , n_t , fun_n , d_t e n_{ug} denotam, respectivamente, o custo de uma partida ou parada de máquina, o valor monetário de 1 MWh, o número de máquinas operando no período t , a função de perdas para n máquinas em operação, a demanda no período t) e o número total de máquinas na usina), tanto para o conjunto CS1 quanto para o CS2, visto que neste o valor de pen será nulo e, portanto, não afetará o cálculo da aptidão. Destaca-se que a abordagem utilizando penalização tem como único propósito aumentar a complexidade do processo e auxiliar nas análises das TICs. O valor 10^4 utilizado no Algoritmo 6 é arbitrário e depende do critério do especialista do problema. Em geral, utiliza-se um valor que seja suficientemente grande para que os indivíduos das TICs reconheçam que um valor alto (em problemas de minimização) de aptidão deve ser evitado.

Algoritmo 6 – Cálculo da penalização na função objetivo.

1. $pen = 0$

2. Faça t variar de 1 a T ;

3. Se $n_t > n_{t_{max}}$

$$a) \quad pen = pen + 10^4 \cdot (n_t - n_{t_{max}})$$

4. Senão, se $n_t < n_{t_{min}}$

$$a) \quad pen = pen + 10^4 \cdot (n_{t_{min}} - n_t)$$

$$\min pen + \sum_{t=1}^T c_{pp} \cdot |n_t - n_{t-1}| + c_{per} \cdot fun_n(d_t) \quad (4.3)$$

s.a :

$$n_t \in \mathbb{Z} \quad (4.4)$$

$$1 \leq n_t \leq n_{ug} \quad (4.5)$$

Como discorrido na Seção 3.1, a formulação de otimização pode ser aplicada considerando-se o custo de uma partida ou parada nulo para que haja uma minimização de perdas ou o custo de perdas nulo para que haja uma minimização de partidas e paradas, de acordo com a intenção do operador. Levando tal fato em consideração em conjunto com a abordagem focada nas vazões, a Tabela 20 apresenta os valores utilizados nas simulações para as quatro seguintes possíveis modalidades:

- MA - Minimização dos custos operacionais conforme algoritmo proposto em (21; 23).
- MB - Minimização das perdas de potência conforme algoritmo proposto em (21; 23).
- MC - Minimização de ocorrências de partidas e paradas.
- MD - Minimização de vazões conforme adaptações expostas na Seção 4.1.

Tabela 20 – Custos em cada modalidade

	MA	MB	MC	MD
Função (fun_n)	Perdas	Perdas	Vazões	Vazões
c_{pp}	500	0	1	0
c_{per}	50	1	0,001	1

Fonte: Elaborada pelo autor (2019).

Nota-se na Tabela 20 o valor unitário de c_{per} e nulo de c_{pp} nas modalidades MB e MD, ou seja, a função objetivo será dada pelos próprios valores de perdas ou vazões totais ao longo do horizonte de programação (assumindo penalização nula). Na modalidade MA, a minimização se dá por uma ponderação entre os dois tipos de custo. Na modalidade MC, c_{per} seria, a princípio, nulo, porém a utilização do valor 0,001 visa direcionar a otimização para que sejam minimizadas as ocorrências de partidas e paradas, no entanto minimizando-se também a utilização de recursos hídricos na operação com partidas e paradas minimizadas, o que não é sempre garantido. Tal fato será esclarecido mais adiante.

Em relação às TICs, utilizou-se: a versão original do SCA com arredondamento, aqui denominada SCAXr, a qual utiliza as Equações 2.7 para atualizar as posições dos indivíduos; a versão modificada do SCA (subseção 2.2.5) com arredondamento, aqui denominada SCAr, a qual utiliza as Equações 2.9; a versão original do GWO com arredondamento,

aqui denominada GWOr; as versões binárias do SCA original e modificado e do GWO adaptadas conforme diretrizes expostas na subseção 2.2.6, denominadas SCAXb, SCAb e GWOb, respectivamente; e, finalmente, o ACO, o qual não requer qualquer adaptação visto que se trata de uma TIC específica para problemas discretos.

Nas versões do SCA e GWO, o coeficiente de exploração a foi considerado igual a 2 (Equação 2.8, passo 5.a) do Algoritmo 1 e passo 6.a) do Algoritmo 3). No ACO, utilizou-se uma taxa de evaporação de 5%. Em todas as TICs, utilizou-se 30 indivíduos e critério de parada de 100 iterações. Foram realizadas 50 simulações de cada TIC em cada modalidade de otimização, tanto no conjunto SC1 quanto no SC2. Além disso, garantiu-se que todas TICs partissem do mesmo conjunto de soluções iniciais, evitando assim possíveis vantagens na busca devido à aleatoriedade na criação da população inicial.

4.2.3.1 Resultados com aplicação de penalizações

Como mencionado anteriormente, os limites inferiores e superiores das variáveis de decisão foram abandonadas no conjunto CS1. Tal medida visa tornar a tarefa mais desafiadora para as TICs, permitindo assim uma exploração mais profunda dos resultados. Análises dentro deste primeiro contexto são expostas a seguir.

A Tabela 21 exhibe os resultados estatísticos obtidos, sendo que a abreviatura DP denota o desvio padrão. Estes também são expostos em forma de *boxplot* nas Figuras 23, 24, 25 e 26, respectivamente às modalidades MA, MB, MC e MD. A Tabela 22 mostra as taxas de acerto de cada TIC (%) e releva, em comparação à melhor solução fornecida pelo GWOb e pelo ACO, a inabilidade dos demais algoritmos em atingir tal solução. As Figuras 27(a) a 27(g), 28(a) a 28(g), 29(a) a 29(g) e 30(a) a 30(g) exibem os comportamentos de evolução da melhor aptidão e das médias das aptidões ao longo das iterações nos algoritmos SCAXr, SCAr, GWOr, SCAXb, SCAb, GWOb e ACO, para uma mesma simulação das modalidades MA, MB, MC e MD, respectivamente. As Figuras 31, 32, 33 e 34 exibem, respectivamente às modalidades MA, MB, MC e MD, os comportamentos das melhores aptidões obtidas por cada algoritmo considerando todas as simulações.

Ressalta-se que as Figuras 27, 28, 29, e 30, as quais contêm as informações de convergência das TICs, se referem à primeira das 50 simulações. Porém, embora as curvas variem em cada simulação, o mesmo padrão de comportamento foi observado em todas simulações. Em relação ao esforço computacional, a Tabela 23 exhibe os tempos médios por simulação (TMS) requisitados por cada TIC em cada modalidade. Todas as simulações foram realizadas em um computador cujas configurações são: Processador AMD Ryzen 5 2600 de 3,40GHz, 8 GB de memória RAM e Windows 10 de 64 *bits*. Embora os tempos de execução das TICs variem de acordo com a máquina, o intuito neste trabalho é realizar comparações entre estes tempos. Nota-se na Tabela 23 diferenças irrelevantes entre os TMS de uma mesma TIC em diferentes modalidades. Percebe-se também valores levemente

Tabela 21 – Resultados estatísticos das aptidões - CS1

		Pior	Melhor	Média	Mediana	DP
MA	SCAxr	$5,0972 \cdot 10^6$	$3,3462 \cdot 10^6$	$4,5304 \cdot 10^6$	$4,5896 \cdot 10^6$	$3,8248 \cdot 10^5$
	SCAr	$4,5868 \cdot 10^6$	$2,6049 \cdot 10^6$	$3,5408 \cdot 10^6$	$3,4677 \cdot 10^6$	$4,3363 \cdot 10^5$
	GWOrr	$2,8284 \cdot 10^6$	$8,4518 \cdot 10^5$	$1,8832 \cdot 10^6$	$1,8481 \cdot 10^6$	$5,0672 \cdot 10^5$
	SCAxb	$3,8408 \cdot 10^6$	$2,3485 \cdot 10^6$	$2,9699 \cdot 10^6$	$2,9706 \cdot 10^6$	$4,0699 \cdot 10^5$
	SCAb	$1,3448 \cdot 10^6$	$9,8961 \cdot 10^4$	$6,7179 \cdot 10^5$	$5,9821 \cdot 10^5$	$3,2258 \cdot 10^5$
	GWOb	$5,9378 \cdot 10^5$	$9,5520 \cdot 10^4$	$1,9161 \cdot 10^5$	$9,7960 \cdot 10^4$	$1,4083 \cdot 10^5$
	ACO	$9,5500 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5180 \cdot 10^4$	$9,5154 \cdot 10^4$	$1,5790 \cdot 10^2$
MB	SCAxr	$2,0190 \cdot 10^5$	$1,6222 \cdot 10^5$	$1,8603 \cdot 10^5$	$1,9189 \cdot 10^5$	$1,1643 \cdot 10^4$
	SCAr	$1,9180 \cdot 10^5$	$1,0255 \cdot 10^5$	$1,4522 \cdot 10^5$	$1,4233 \cdot 10^5$	$1,9419 \cdot 10^4$
	GWOrr	$1,3212 \cdot 10^5$	$4,3083 \cdot 10^4$	$8,0514 \cdot 10^4$	$8,2677 \cdot 10^4$	$1,9178 \cdot 10^4$
	SCAxb	$1,4230 \cdot 10^5$	$8,2832 \cdot 10^4$	$1,1927 \cdot 10^5$	$1,2239 \cdot 10^5$	$1,3626 \cdot 10^4$
	SCAb	$4,3160 \cdot 10^4$	$1,3484 \cdot 10^4$	$2,2794 \cdot 10^4$	$2,3368 \cdot 10^4$	$9,0110 \cdot 10^3$
	GWOb	$2,3402 \cdot 10^4$	$3,6071 \cdot 10^3$	$5,3894 \cdot 10^3$	$3,6132 \cdot 10^3$	$4,3226 \cdot 10^3$
	ACO	$3,6357 \cdot 10^3$	$3,6143 \cdot 10^3$	$3,6273 \cdot 10^3$	$3,6278 \cdot 10^3$	$4,6551 \cdot 10^0$
MC	SCAxr	$4,3030 \cdot 10^5$	$3,0030 \cdot 10^5$	$3,7732 \cdot 10^5$	$3,8034 \cdot 10^5$	$3,1391 \cdot 10^4$
	SCAr	$3,5028 \cdot 10^5$	$1,7023 \cdot 10^5$	$2,4224 \cdot 10^5$	$2,4025 \cdot 10^5$	$4,1072 \cdot 10^4$
	GWOrr	$9,0152 \cdot 10^4$	$1,0594 \cdot 10^2$	$2,7326 \cdot 10^4$	$2,0131 \cdot 10^4$	$2,4089 \cdot 10^4$
	SCAxb	$3,2029 \cdot 10^5$	$1,9024 \cdot 10^5$	$2,4947 \cdot 10^5$	$2,5026 \cdot 10^5$	$3,5575 \cdot 10^4$
	SCAb	$1,4019 \cdot 10^5$	$1,0118 \cdot 10^4$	$5,1947 \cdot 10^4$	$5,0150 \cdot 10^4$	$2,9203 \cdot 10^4$
	GWOb	$4,0137 \cdot 10^4$	$1,0110 \cdot 10^2$	$1,0111 \cdot 10^4$	$1,0112 \cdot 10^4$	$1,1074 \cdot 10^4$
	ACO	$1,0223 \cdot 10^2$	$9,7314 \cdot 10^1$	$9,8316 \cdot 10^1$	$9,7745 \cdot 10^1$	$1,1777 \cdot 10^0$
MD	SCAxr	$2,5411 \cdot 10^5$	$2,0924 \cdot 10^5$	$2,3169 \cdot 10^5$	$2,3221 \cdot 10^5$	$9,6773 \cdot 10^3$
	SCAr	$2,3076 \cdot 10^5$	$1,6608 \cdot 10^5$	$2,0042 \cdot 10^5$	$1,9914 \cdot 10^5$	$1,4098 \cdot 10^4$
	GWOrr	$1,7533 \cdot 10^5$	$1,2156 \cdot 10^5$	$1,5138 \cdot 10^5$	$1,5173 \cdot 10^5$	$1,2484 \cdot 10^4$
	SCAxb	$2,0544 \cdot 10^5$	$1,5258 \cdot 10^5$	$1,8053 \cdot 10^5$	$1,8237 \cdot 10^5$	$1,2474 \cdot 10^4$
	SCAb	$1,2171 \cdot 10^5$	$9,1697 \cdot 10^4$	$1,0390 \cdot 10^5$	$1,0623 \cdot 10^5$	$7,7807 \cdot 10^3$
	GWOb	$9,8983 \cdot 10^4$	$9,1637 \cdot 10^4$	$9,2956 \cdot 10^4$	$9,1641 \cdot 10^4$	$2,8263 \cdot 10^3$
	ACO	$9,1880 \cdot 10^4$	$9,1757 \cdot 10^4$	$9,1816 \cdot 10^4$	$9,1816 \cdot 10^4$	$2,9476 \cdot 10^1$

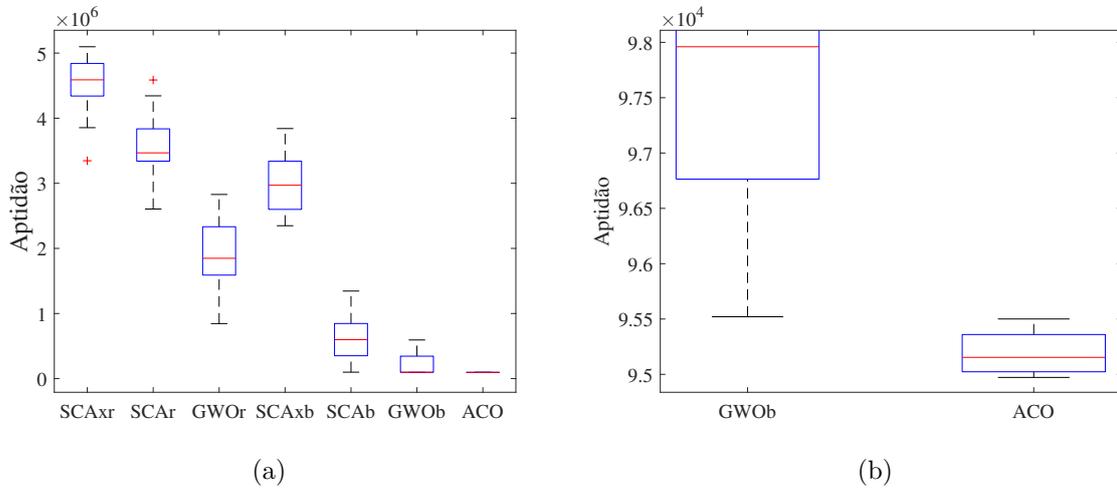
Fonte: Elaborada pelo autor (2019).

Tabela 22 – Taxas de acerto, em %, de cada TIC - CS1

	SCAxr	SCAr	GWOrr	SCAxb	SCAb	GWOb	ACO
MA	0	0	0	0	0	0	22
MB	0	0	0	0	0	32	0
MC	0	0	0	0	0	0	36
MD	0	0	0	0	0	48	0

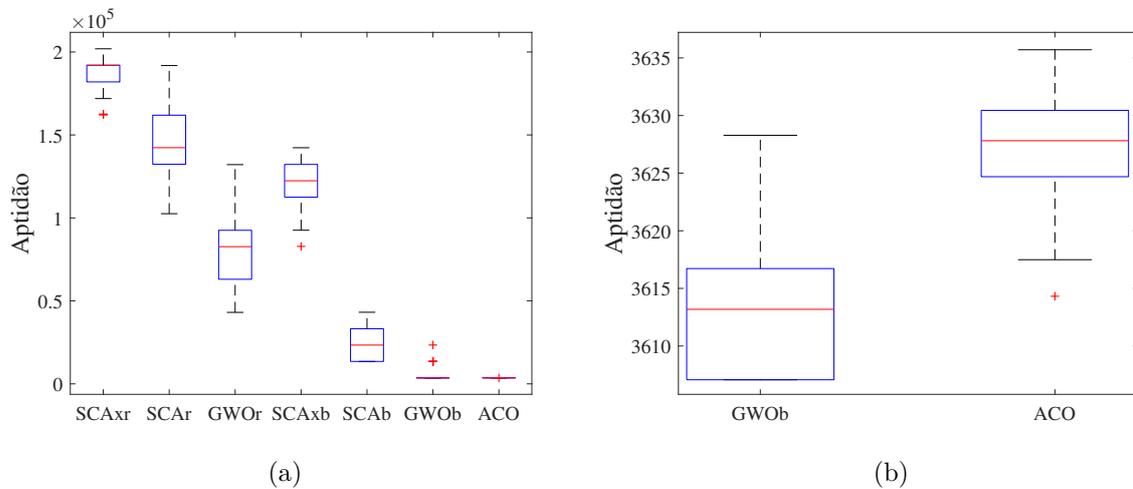
Fonte: Elaborada pelo autor (2019).

Figura 23 – Boxplot das aptidões obtidas em 50 simulações da modalidade MA, sendo (a) a figura completa e (b) a figura com zoom para melhor visualização



Fonte: Elaborada pelo autor (2019).

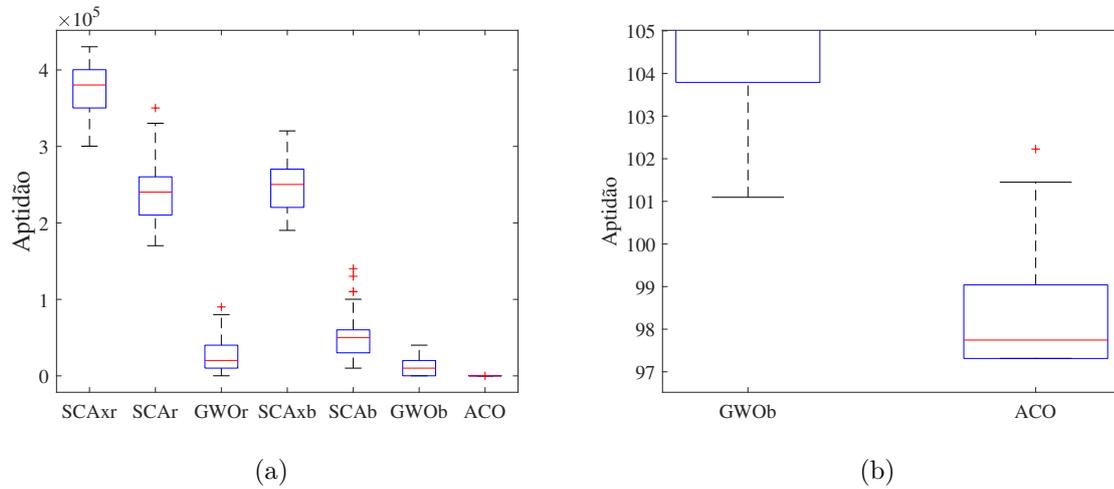
Figura 24 – Boxplot das aptidões obtidas em 50 simulações da modalidade MB, sendo (a) a figura completa e (b) a figura com zoom para melhor visualização



Fonte: Elaborada pelo autor (2019).

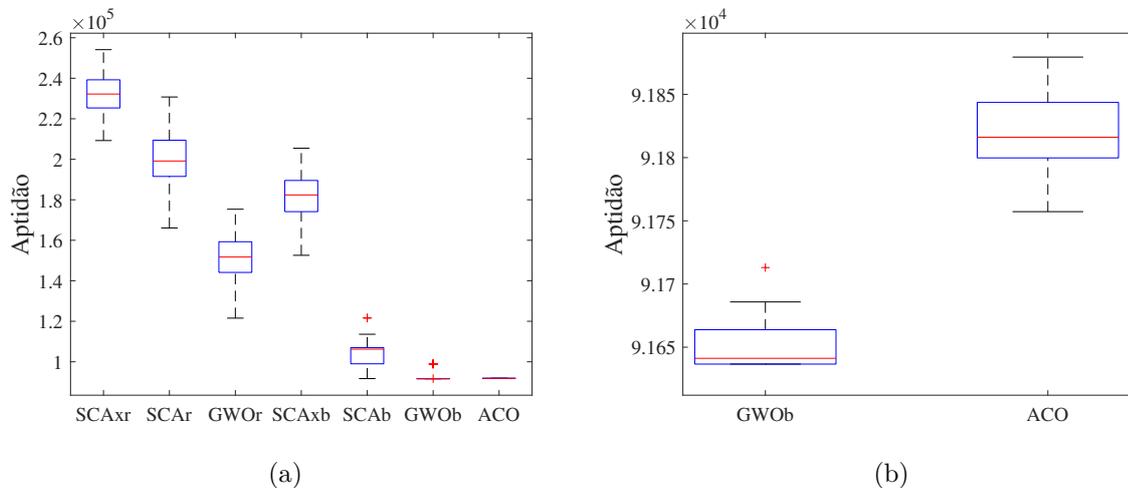
maiores da versão arredondada do GWO em relação às versões arredondadas do SCA, apesar de o contrário acontecer nas versões binárias. Destaca-se que ainda assim tais diferenças são de impacto praticamente nulo. Uma das diferenças mais significativas está entre as versões arredondadas comparadas às versões binárias, em que houve um aumento de aproximadamente 20 vezes nos TMS. Tal fator é consequência direta do passo 6.b)vii.A. do Algoritmo 3, visto que a geração randômica de novos valores pode “prender” a TIC em um *loop* por várias tentativas até que se obtenha um valor viável. A segunda diferença expressiva está nos tempos exigidos pelo ACO, que claramente se mostrou uma TIC que requer mais esforço computacional que as demais, pelo menos no problema aqui tratado.

Figura 25 – Boxplot das aptidões obtidas em 50 simulações da modalidade MC, sendo (a) a figura completa e (b) a figura com zoom para melhor visualização



Fonte: Elaborada pelo autor (2019).

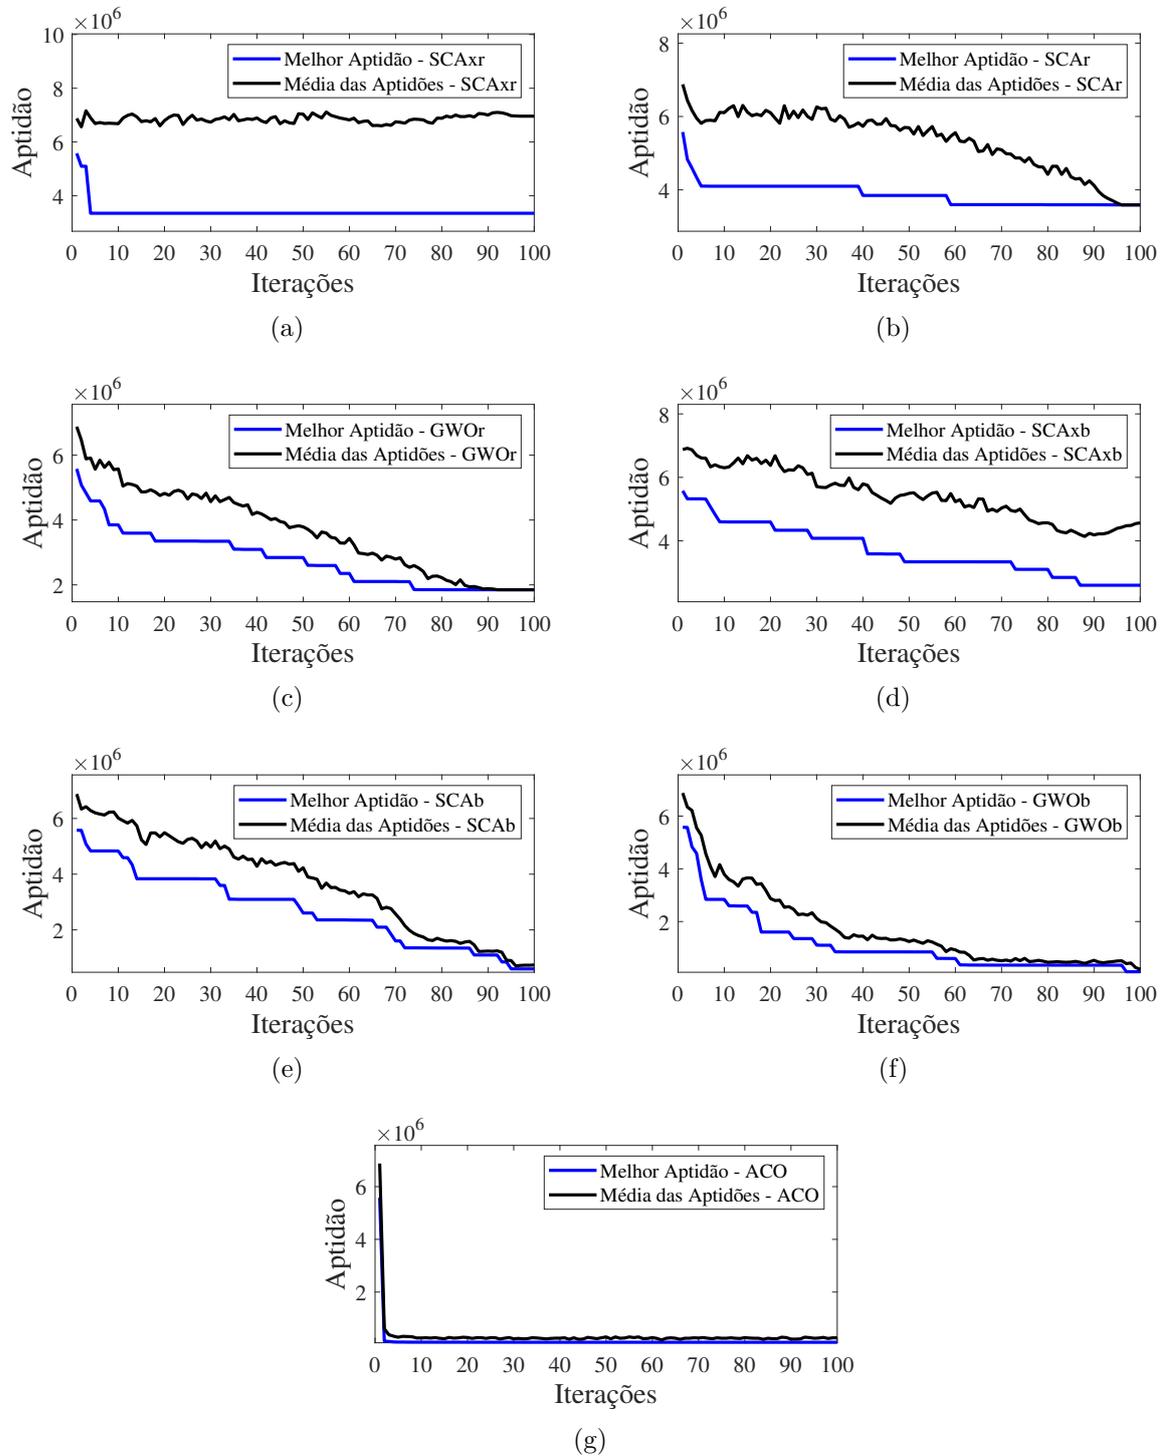
Figura 26 – Boxplot das aptidões obtidas em 50 simulações da modalidade MD, sendo (a) a figura completa e (b) a figura com zoom para melhor visualização



Fonte: Elaborada pelo autor (2019).

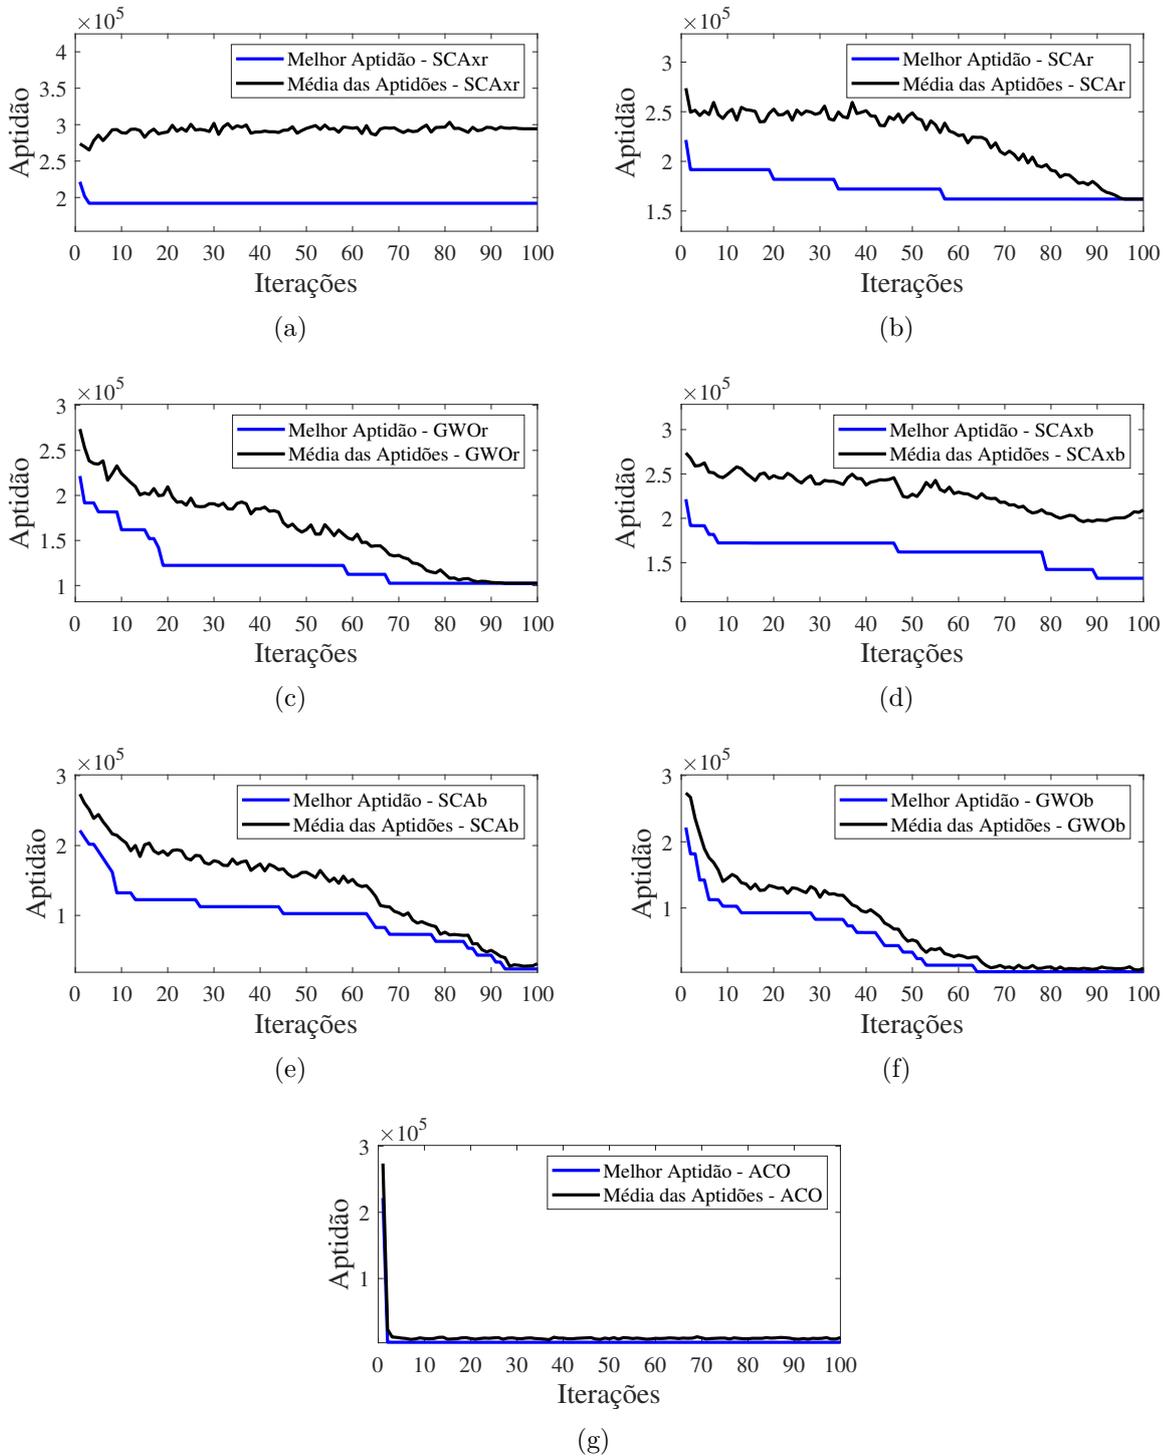
O primeiro ponto importante a se notar diz respeito à modificação do SCA exibida na subseção 2.2.5. Verifica-se nas Figuras 23, 24, 25 e 26 e na Tabela 21 o desempenho superior do SCA modificado em relação ao original, tanto na versão arredondada quanto na binária e em todas as modalidades. De fato, percebe-se também nas Figuras 27(a), 28(a), 29(a) e 30(a) que as médias das aptidões obtidas pelo SCAxr não apresentam um padrão de redução ao longo das iterações. Tal fato evidencia que o SCA realiza uma busca mais eficiente quando as possíveis novas posições dos indivíduos estão ao redor do ponto de destino, isto é, da melhor solução encontrada a cada iteração.

Figura 27 – Comportamento de convergência nas TICs: (a) SCAXr, (b) SCAR, (c) GWOr, (d) SCAXb, (e) SCAb, (f) GWOb e (g) ACO, na modalidade MA



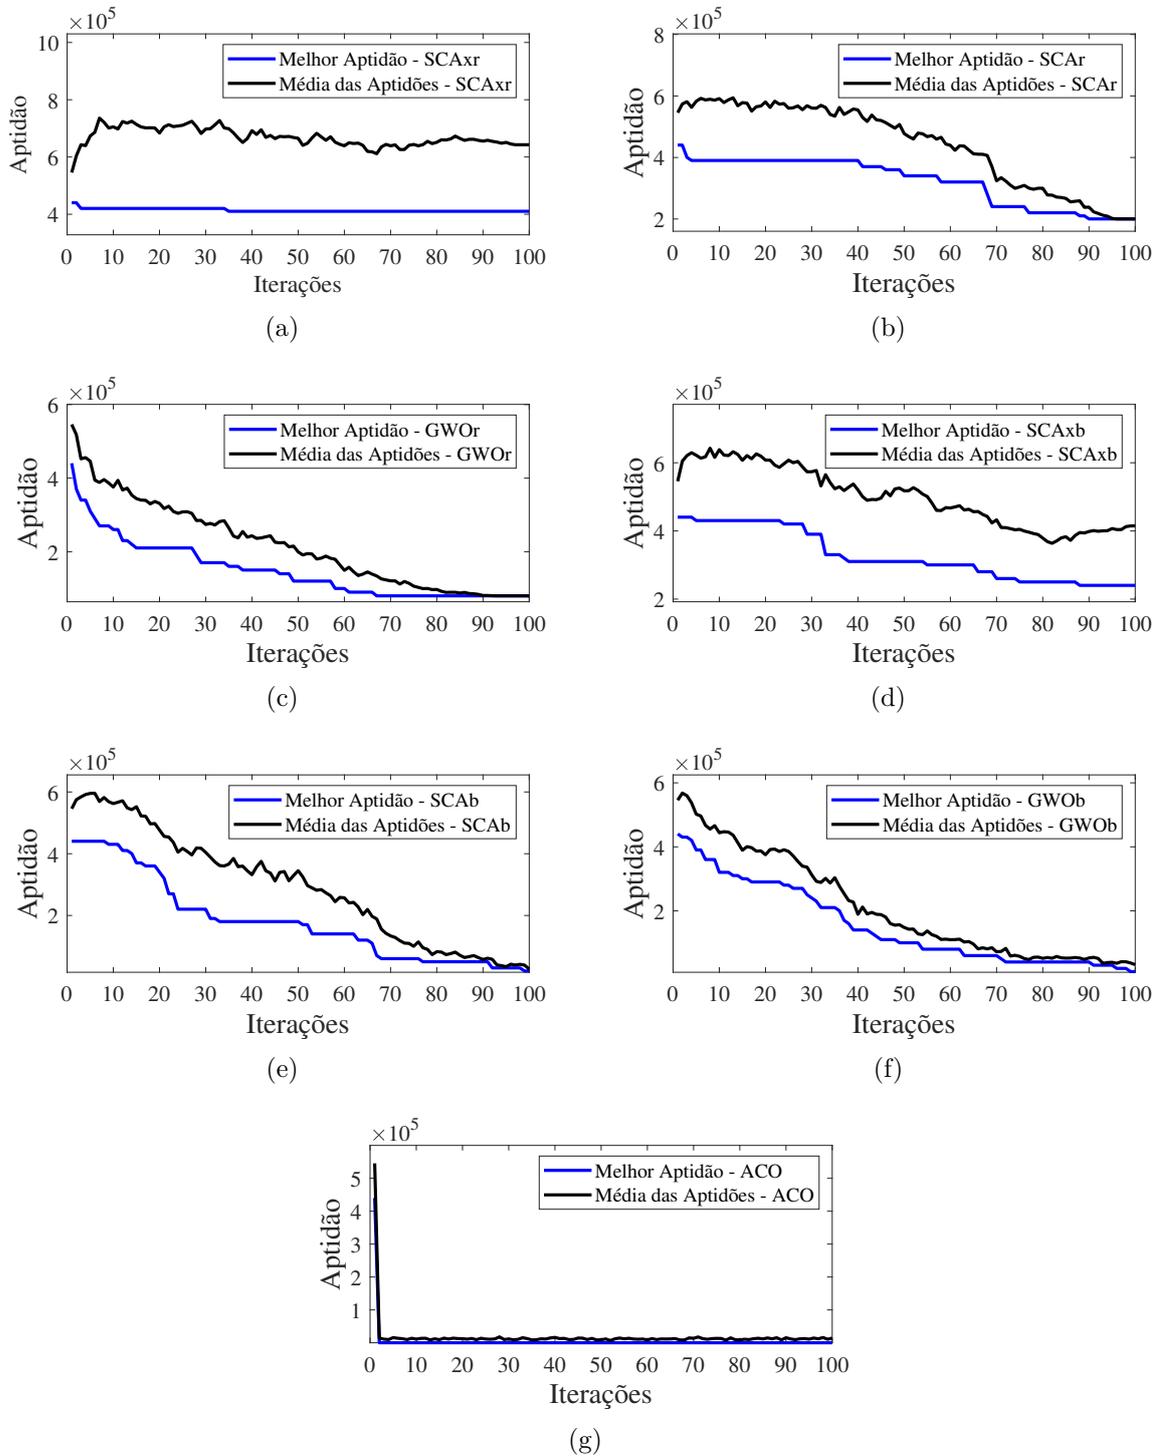
Fonte: Elaborada pelo autor (2019).

Figura 28 – Comportamento de convergência nas TICs: (a) SCAXr, (b) SCAR, (c) GWOr, (d) SCAXb, (e) SCAb, (f) GWOb e (g) ACO, na modalidade MB



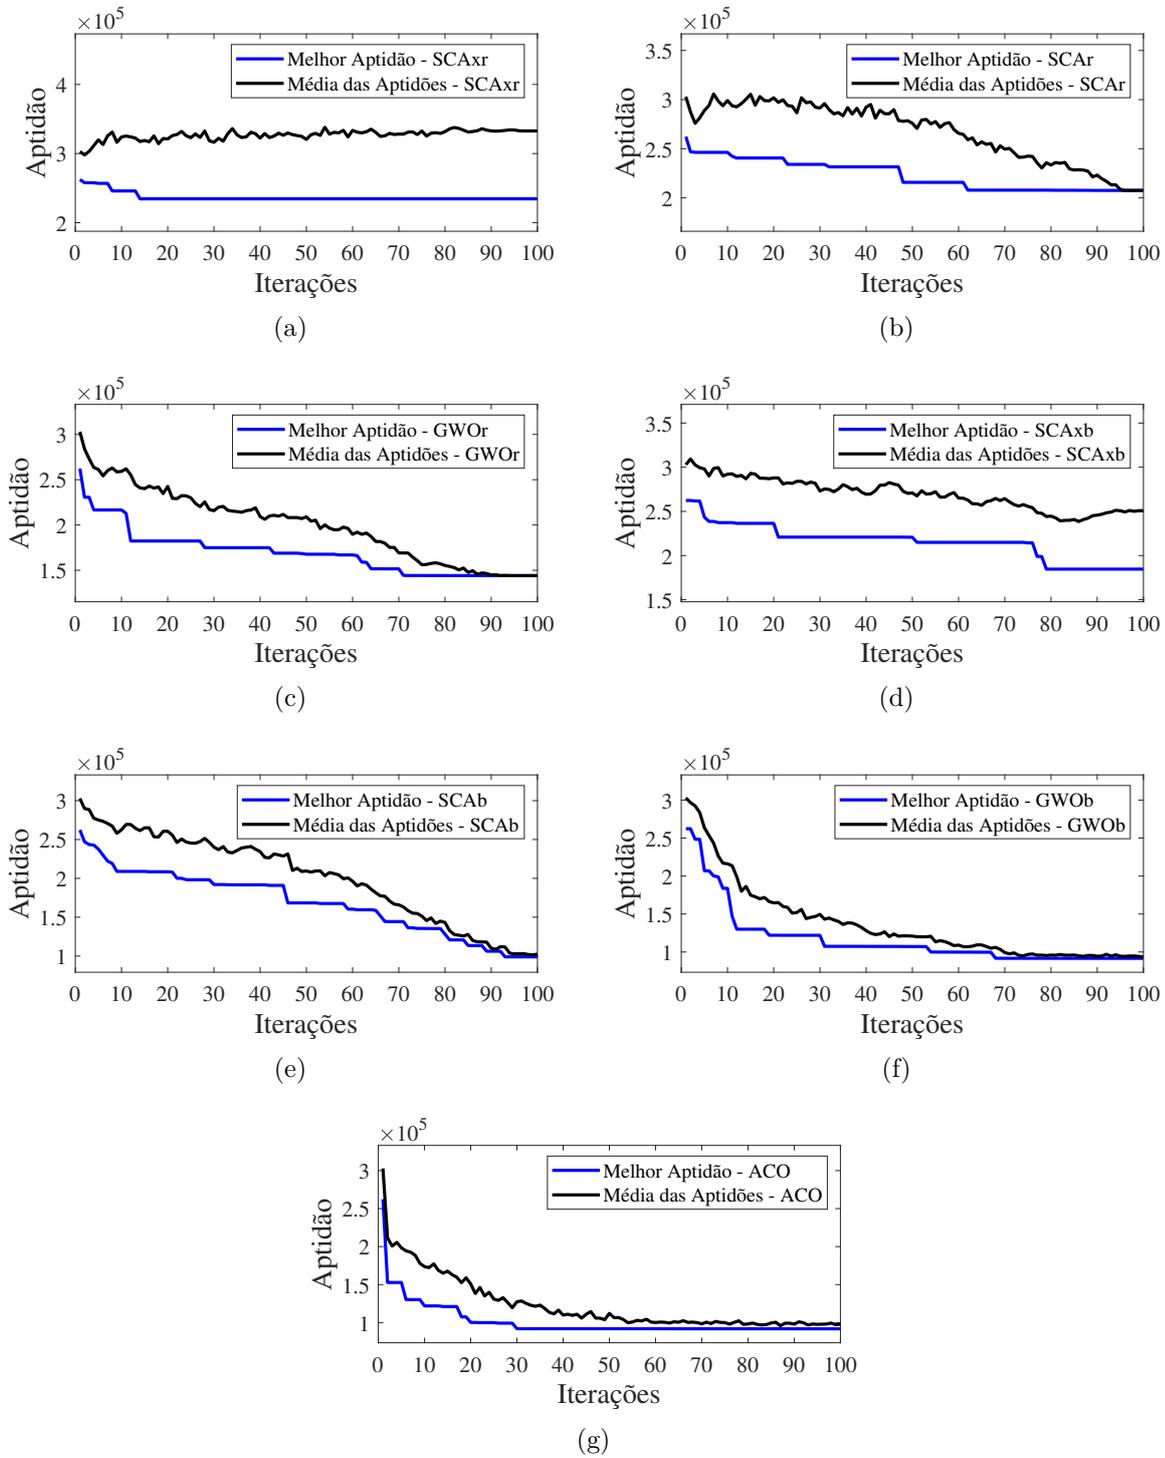
Fonte: Elaborada pelo autor (2019).

Figura 29 – Comportamento de convergência nas TICs: (a) SCAXr, (b) SCAR, (c) GWOr, (d) SCAXb, (e) SCAB, (f) GWOb e (g) ACO, na modalidade MC



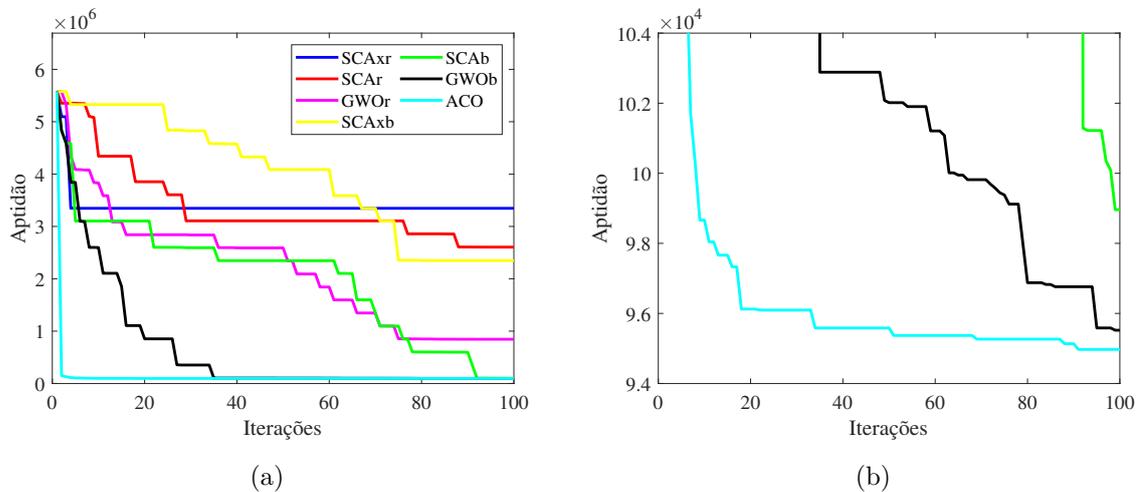
Fonte: Elaborada pelo autor (2019).

Figura 30 – Comportamento de convergência nas TICs: (a) SCAXr, (b) SCAr, (c) GWOr, (d) SCAXb, (e) SCAb, (f) GWOb e (g) ACO, na modalidade MD



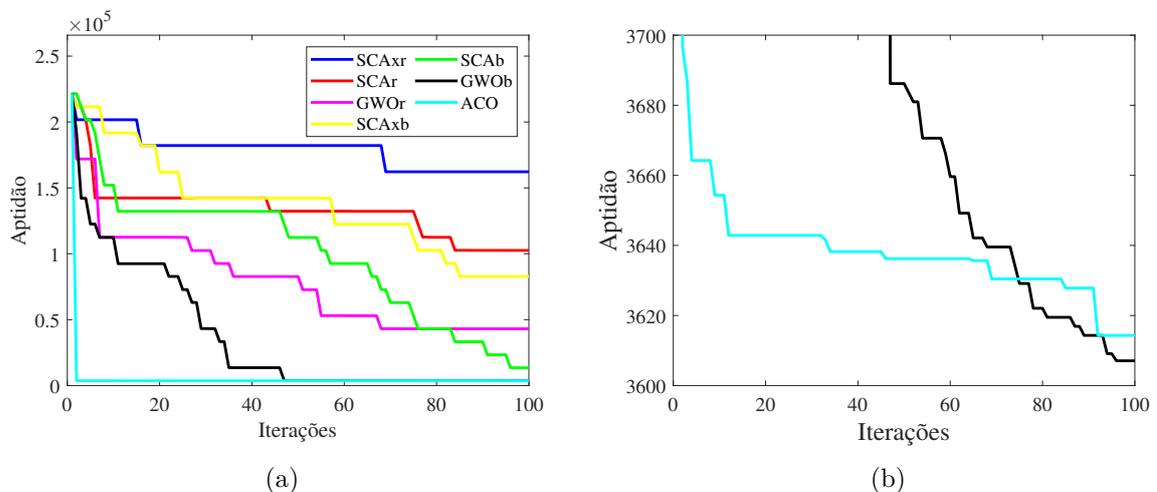
Fonte: Elaborada pelo autor (2019).

Figura 31 – Convergência dos melhores indivíduos de cada TIC na modalidade MA, sendo (a) a figura completa e (b) a figura com zoom para melhor visualização



Fonte: Elaborada pelo autor (2019).

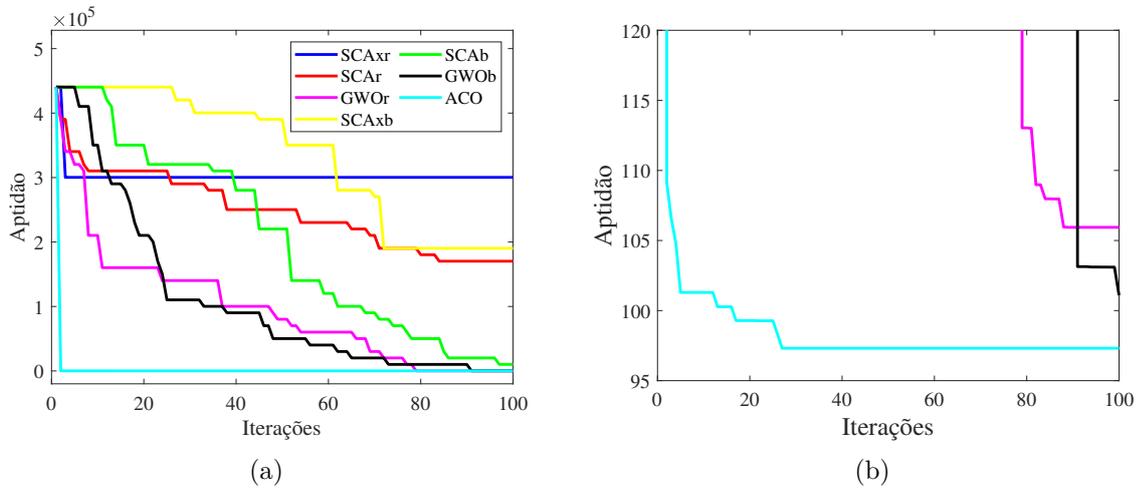
Figura 32 – Convergência dos melhores indivíduos de cada TIC na modalidade MB, sendo (a) a figura completa e (b) a figura com zoom para melhor visualização



Fonte: Elaborada pelo autor (2019).

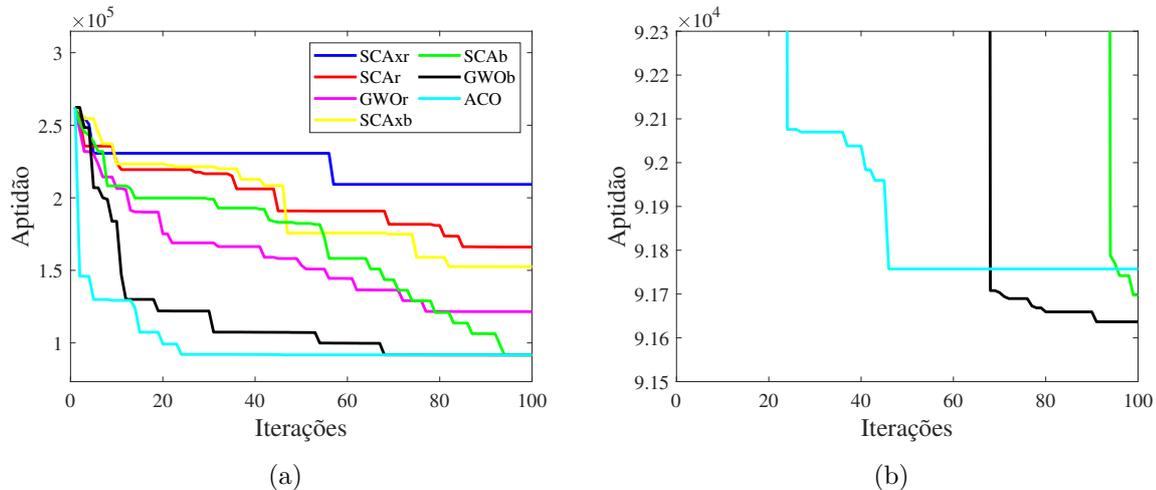
Observa-se nas Figuras 31, 32, 33 e 34 a queda extremamente rápida do valor de aptidão obtida pelo melhor indivíduo do ACO, atingindo valores muito próximos à solução ótima em menos que 5% do número máximo de iterações. Tal ocorrência mostra a capacidade do ACO em rapidamente escapar da região inviável, independente de se no fim do processo ter sido esta TIC a que forneceu ou não a melhor resposta entre as TICs analisadas. Esta característica se deve ao fato de o ACO associar a cada valor da região de busca uma probabilidade inversamente proporcional ao valor de aptidão, ou seja, valores inviáveis, os quais possuem elevadas aptidões por conta da penalização da função objetivo, terão probabilidades baixíssimas de serem atribuídos a uma posição do indivíduo. Nota-se

Figura 33 – Convergência dos melhores indivíduos de cada TIC na modalidade MC, sendo (a) a figura completa e (b) a figura com zoom para melhor visualização



Fonte: Elaborada pelo autor (2019).

Figura 34 – Convergência dos melhores indivíduos de cada TIC na modalidade MD, sendo (a) a figura completa e (b) a figura com zoom para melhor visualização



Fonte: Elaborada pelo autor (2019).

também nas figuras mencionadas os desempenhos precários dos algoritmos SCAXr, SCAr, SCAXb e, em menor proporção, do GWOr.

Em relação aos planejamentos de unidades geradoras fornecidos pelas TICs, as seguintes afirmações foram constatadas como consequências das simulações:

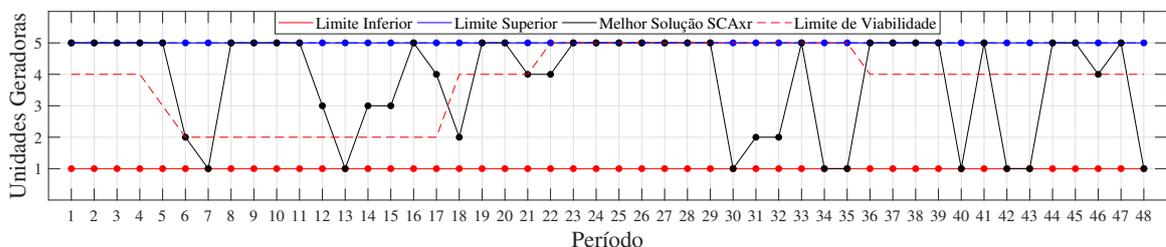
- Os melhores indivíduos do SCAXr, SCAr e SCAXb foram incapazes de evitar a região inviável em todas as modalidades, fornecendo operações como a mostrada na Figura 35, a qual exibe o caso de melhor solução obtida pelo SCAXr na modalidade MA, sendo a região viável demarcada pelo Limite de Viabilidade e o Limite Superior;

Tabela 23 – Tempos médios de simulação

	MA	MB	MC	MD
	TMS (s)	TMS (s)	TMS (s)	TMS (s)
SCA_{xr}	0,0323 ± 0,0045	0,0301 ± 0,0028	0,0317 ± 0,0031	0,0303 ± 0,0026
SCA_r	0,0308 ± 0,0029	0,0293 ± 0,0017	0,0311 ± 0,0027	0,0302 ± 0,0032
GWO_r	0,0362 ± 0,0058	0,0345 ± 0,0052	0,0353 ± 0,0030	0,0348 ± 0,0026
SCA_{xb}	0,6946 ± 0,0425	0,6879 ± 0,0446	0,6804 ± 0,0250	0,6763 ± 0,0179
SCA_b	0,6842 ± 0,0467	0,6858 ± 0,0341	0,6687 ± 0,0239	0,6685 ± 0,0231
GWO_b	0,6476 ± 0,0476	0,6262 ± 0,0312	0,6229 ± 0,0284	0,6150 ± 0,0204
ACO	1,6131 ± 0,0594	1,6010 ± 0,0511	1,5738 ± 0,0403	1,5660 ± 0,0430

Fonte: Elaborada pelo autor (2019).

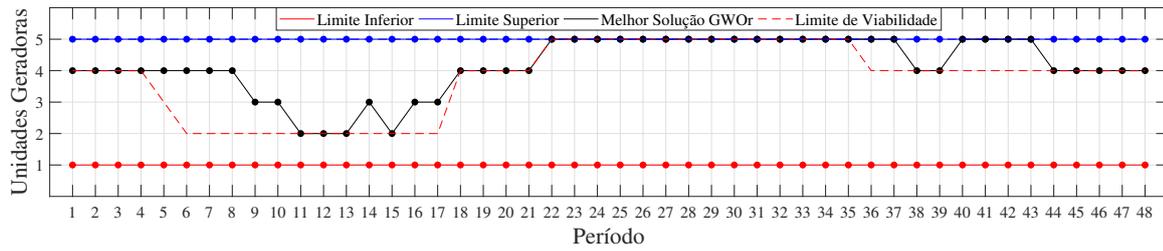
- As melhores soluções do GWO_r foram inviáveis nas modalidades MA, MB e MD, ou seja, mesmo garantindo uma solução viável na modalidade MC (exibida na Figura 36), esta TIC não é adequada para este tipo de problema, o que é reforçado pelo fato de a solução em questão não ser a melhor na referida modalidade;
- No SCA_b, as melhores soluções são inviáveis nas modalidades MB e MC, as quais são exibidas nas Figuras 37 e 38, respectivamente. Nota-se nestas figuras que houve violação da região viável em apenas um período, porém tal fato é suficiente para comprometer a aplicação desta TIC, pelo menos nas modalidades em questão;
- Os melhores indivíduos do GWO_b e do ACO forneceram soluções viáveis em todas as modalidades, mesmo quando não garantindo a melhor solução possível;
- As violações da região viável foram mais graves no SCA_{xr}, sendo atenuadas gradativamente no SCA_{xb}, SCA_r, GWO_r e SCA_b, nesta ordem.

Figura 35 – Melhor planejamento fornecido pelo SCA_{xr} na modalidade MA

Fonte: Elaborada pelo autor (2019).

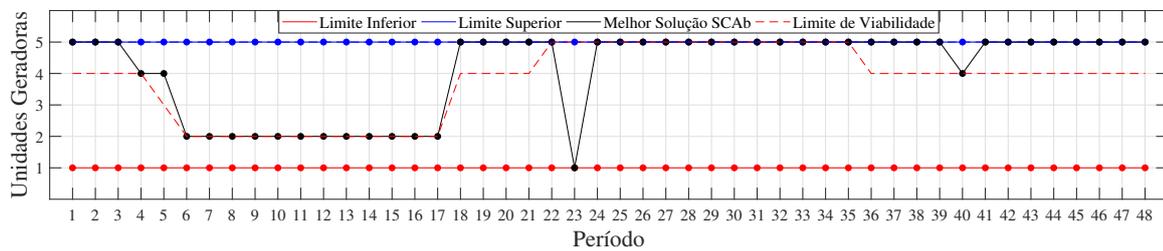
Enfatiza-se que encontrar soluções dentro da região viável é de importância crucial em qualquer problema, visto que a violação de tal fator implica na impossibilidade de aplicar a resposta obtida pela TIC. Ou seja, a utilização de TICs em suas formas originais,

Figura 36 – Melhor planejamento fornecido pelo GWOr na modalidade MC



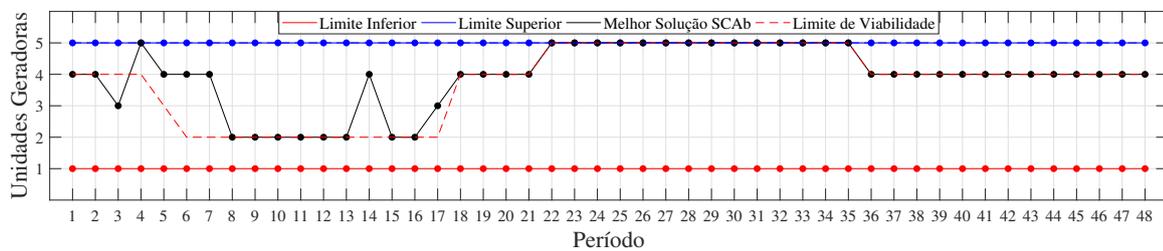
Fonte: Elaborada pelo autor (2019).

Figura 37 – Melhor planejamento fornecido pelo SCAb na modalidade MB



Fonte: Elaborada pelo autor (2019).

Figura 38 – Melhor planejamento fornecido pelo SCAb na modalidade MC



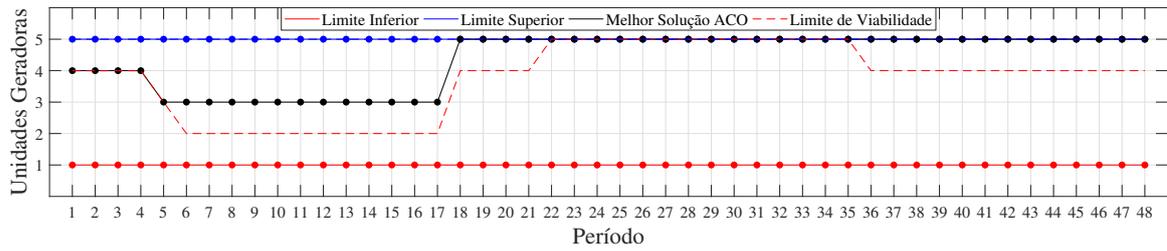
Fonte: Elaborada pelo autor (2019).

porém com arredondamento, em problemas discretos não é adequada. As configurações ótimas nas modalidades MA, MB, MC e MD encontram-se expostas nas Figuras 39, 40, 41 e 42.

Na modalidade MA, a melhor solução obtida foi fornecida exclusivamente pelo ACO. Nota-se na Figura 39 que o planejamento fornecido por esta TIC é bem comportado e, ao contrário dos planejamentos obtidos pelas demais TICs, não apresenta partida ou parada em intervalos com a mesma meta de geração. Pode-se observar na Tabela 21 que a aptidão fornecida pelo ACO é de fato menor, o que também pode ser visto na Figura 31.

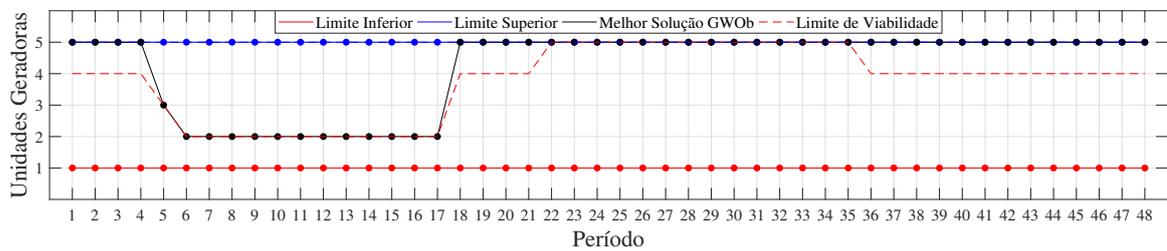
Na modalidade MB, somente o GWOb foi capaz de fornecer a melhor solução obtida. Embora esta TIC não convirja tão rapidamente para regiões viáveis quanto o ACO, e este tenha apresentado melhores aptidões durante a maior parte das iterações,

Figura 39 – Melhor planejamento fornecido pelo ACO na modalidade MA



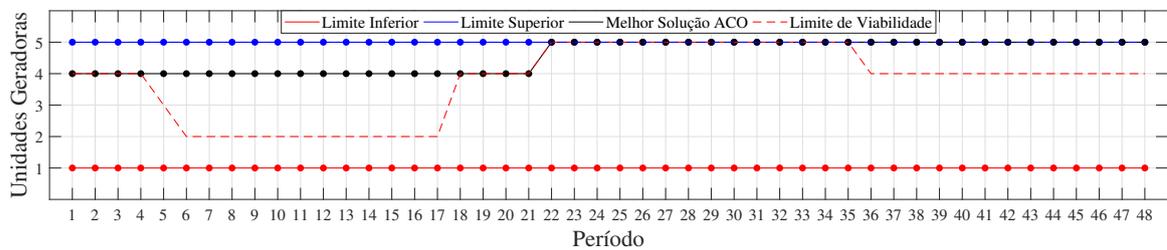
Fonte: Elaborada pelo autor (2019).

Figura 40 – Melhor planejamento fornecido pelo GWOb na modalidade MB



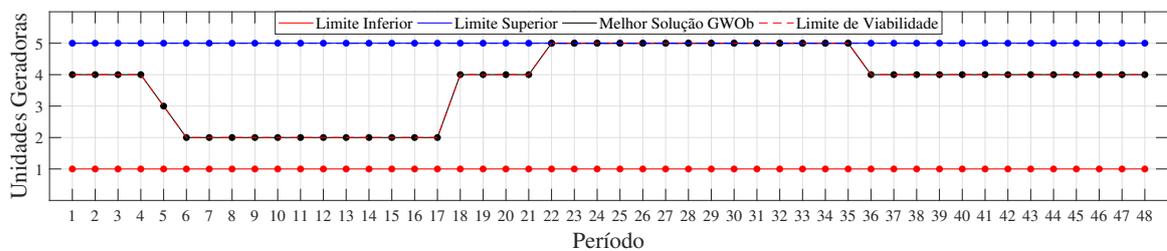
Fonte: Elaborada pelo autor (2019).

Figura 41 – Melhor planejamento fornecido pelo ACO na modalidade MC



Fonte: Elaborada pelo autor (2019).

Figura 42 – Melhor planejamento fornecido pelo GWOb na modalidade MD



Fonte: Elaborada pelo autor (2019).

nota-se na Figura 32 que no fim do processo de otimização o GWOb foi capaz de refinar a melhor solução além do que possibilitado pelo ACO. A Tabela 21 evidencia o melhor

desempenho do GWOb nesta modalidade. Pode-se constatar que a solução encontrada é a ótima global, já que esta modalidade se trata de uma minimização de perdas de potência. Para tal, basta notar na Tabela 17 que para cada meta de geração, o valor mínimo de perdas observado na Figura 21 é de fato dado pelo número de unidades geradoras exibido na Figura 40.

Na modalidade MC, novamente o ACO foi o único a fornecer a melhor solução obtida. É trivial perceber na Figura 41 que o planejamento fornecido é de fato o ótimo global, visto que se trata de uma minimização de partidas e paradas. Tendo em consideração que o número de unidades geradoras operando antes do período de otimização é nulo, tem-se um total de 5 partidas ao longo do horizonte de programação. Nota-se também a importância nesta modalidade de se adicionar na função objetivo (Equação 4.3) o valor 0,001 para c_{per} , pois do ponto de vista exclusivo da quantidade de partidas e paradas, operar a UHE com cinco unidades geradoras durante todo o dia também acarretaria 5 partidas. No entanto, entre os períodos 1 e 21 tem-se uma menor vazão turbinada utilizando-se quatro unidades geradoras que utilizando-se 5, o que pode ser verificado cruzando as informações da Tabela 17 com a Figura 22.

Na modalidade MD, o GWOb mais uma vez forneceu a melhor solução. O refinamento final da solução novamente foi inferior por parte do ACO, o qual, inclusive, obteve uma solução inferior à fornecida pelo SCAB, o que pode ser observado na Figura 34. Analogamente à modalidade MB, certifica-se via Tabela 17 e Figura 22 que a solução fornecida pelo GWOb é de fato a ótima global, visto que os números de unidades geradoras em cada período exibidos na Figura 42 garantem a menor vazão turbinada. Por coincidência, a solução ótima é dada pelas quantidades mínimas de unidades geradoras que podem atender a demanda.

O leitor talvez questione a necessidade de se utilizar uma ferramenta de otimização nas modalidades MB e MD, já que é possível determinar os valores ótimos de unidades geradoras a operar ao se analisar as Funções de Perdas de Potência e as Funções de Vazões em conjunto com as metas de geração. Tal afirmativa é verdadeira, no entanto, busca-se neste trabalho uma investigação das TICs que visa contribuir para aplicações das mesmas em problemas similares, porém que não possibilitem a determinação da solução ótima a partir dos dados de entrada.

As modalidades MA e MC tiveram as respectivas melhores soluções fornecidas pelo ACO, enquanto que nas modalidades MB e MD estas foram obtidas via GWOb. Novamente é válido mencionar o Teorema “*No Free Lunch*”, já que para diferentes formas da função objetivo do problema oriundas dos valores dos custos exibidos na Tabela 20, diferentes TICs apresentaram o melhor desempenho.

Um ponto de grande importância a se destacar diz respeito às taxas de acerto até então apresentadas (Tabela 22). Embora estas sejam relativamente baixas, deve-se ter em

mente que foram obtidas utilizando-se 30 indivíduos realizando a busca ao longo de 100 iterações, valores estes que são consideravelmente baixos para aplicações em problemas reais. Os motivos para a escolha de tais valores são: (i) menores tempos de simulação e (ii) possibilidade de testar as TICs em condições menos favoráveis. Para demonstrar a eficácia das TICs aqui estudadas na resolução do problema proposto, ou seja, da otimização da operação diária de UHEs, outras simulações foram realizadas visando a análise exclusiva das taxas de acertos (TA) e dos tempos de execução. Nestas novas simulações, foram utilizados em todas as TICs pesquisadas parâmetros distintos, os quais são: população de 100 indivíduos e critério de parada de 300 iterações. Os resultados encontram-se na Tabela 24 e são discutidos nos parágrafos a seguir.

Tabela 24 – Taxas de acerto e TMS de cada TIC com mais indivíduos e iterações - CS1

	MA		MB	
	TA (%)	TMS (s)	TA (%)	TMS (s)
SCA_{xr}	0	0,2951 ± 0,0163	0	0,2958 ± 0,0145
SCA_r	0	0,2913 ± 0,0172	0	0,2898 ± 0,0144
GWO_r	0	0,3555 ± 0,0303	0	0,3484 ± 0,0183
SCA_{xb}	0	6,7481 ± 0,2078	0	6,7222 ± 0,1521
SCA_b	4	6,6874 ± 0,1627	100	6,6506 ± 0,1073
GWO_b	10	6,4496 ± 0,2130	100	6,3845 ± 0,1226
ACO	86	14,9382 ± 0,3576	88	14,8498 ± 0,2276
	MC		MD	
	TA (%)	TMS (s)	TA (%)	TMS (s)
SCA_{xr}	0	0,3518 ± 0,0867	0	0,2958 ± 0,0282
SCA_r	0	0,3383 ± 0,0859	0	0,2881 ± 0,0148
GWO_r	0	0,3980 ± 0,0958	0	0,3463 ± 0,0155
SCA_{xb}	0	6,7488 ± 0,1944	0	6,7132 ± 0,2217
SCA_b	0	6,7192 ± 0,1860	100	6,6963 ± 0,2107
GWO_b	0	6,4238 ± 0,1837	100	6,4097 ± 0,2215
ACO	100	14,8389 ± 0,2409	0	14,8862 ± 0,4220

Fonte: Elaborada pelo autor (2019).

Na modalidade MA, na qual somente o ACO havia fornecido a solução ótima, o SCAB e o GWO_b também a forneceram com os novos parâmetros, porém com taxas muito baixas, mantendo estas TICs classificadas como não ideias neste caso. A taxa de acerto do ACO passou de 22% (Tabela 22) com os parâmetros anteriores para 86%, o que significa que, em uma aplicação real, seria possível, por exemplo, utilizar estes parâmetros com 5 execuções do ACO para então extrair a melhor solução como resposta definitiva, o que forneceria uma confiabilidade de 99,9946% e levaria menos de 1 minuto e 20 segundos para finalizar a otimização, ou seja, um tempo totalmente viável.

Na modalidade MB, na qual somente o GWOb havia fornecido a solução ótima com uma taxa de acerto de 32% (Tabela 22), o SCAb e o ACO tiveram taxas de acerto de 100% e 88%, respectivamente, com os novos parâmetros, sendo que a taxa de acerto do GWOb também passou para 100%. Em uma otimização real, o SCAb ou o GWOb poderiam ser aplicado com apenas 1 execução ou, como medida de extrema cautela e precaução, 2 ou 3 execuções, o que levaria menos de 25 segundos.

Na modalidade MC, assim como nas simulações com os parâmetros anteriores, somente o ACO forneceu a solução ótima. Porém, com os novos parâmetros, a taxa de acerto passou de 36% (Tabela 22) para 100%. Analogamente à modalidade MB, 2 ou 3 execuções do ACO poderiam ser aplicadas em uma otimização real, o que levaria menos de 50 segundos.

Na modalidade MD, na qual somente o GWOb havia fornecido a solução ótima com uma taxa de acerto de 48% (Tabela 22), o SCAb, assim como o GWOb, obteve uma taxa de acerto de 100% com os novos parâmetros. Analogamente às modalidades MB e MC, 2 ou 3 execuções do SCAb ou GWOb poderiam ser aplicadas em uma otimização real, o que levaria menos de 25 segundos.

Enfatiza-se que as melhores soluções obtidas em todas as modalidades com os novos parâmetros são as mesmas que as obtidas com os parâmetros anteriores, porém com taxas de acerto superiores, isto é, os valores de aptidão dos melhores indivíduos são os mesmos exibidos na Tabela 21 e as configurações de unidades geradoras são as mesmas que expostas nas Figuras 39, 40, 41 e 42 para as modalidades MA, MB, MC e MD, respectivamente.

4.2.3.2 *Resultados com aplicação de limites*

As simulações realizadas no conjunto CS2 levam em consideração os limites calculados via Algoritmo 5 e exibidos na Tabela 19. Tais limites são calculados com base nas metas de geração (Tabela 17) e nas gerações mínimas e máximas fornecidas por cada possibilidade de operação da usina (Tabela 18) e permitem que as TICs fixem as variáveis dentro da região viável de solução após a atualização dos indivíduos, tornando portanto o processo de otimização menos árduo. Os parágrafos seguintes exibem os resultados obtidos dentro deste contexto.

Um ponto importante a se mencionar é que os tempos de simulação no conjunto CS2 (com imposição de limites) foram estatisticamente iguais aos tempos de simulação no conjunto CS1 (sem imposição de limites), ou seja, pode-se basear nas Tabelas 23, para 30 indivíduos e 100 iterações, e 24, para 100 indivíduos e 300 iterações, para avaliar o esforço computacional das simulações no conjunto CS2. Tal fato indica que os tempos de execução das TICs têm ligação com os números de indivíduos e iterações em vez de com os mecanismos que definem a região de busca.

Tabela 25 – Resultados estatísticos das aptidões - CS2

		Pior	Melhor	Média	Mediana	DP
MA	SCA _{xr}	$1,0228 \cdot 10^5$	$9,8508 \cdot 10^4$	$1,0119 \cdot 10^5$	$1,0150 \cdot 10^5$	$9,8110 \cdot 10^2$
	SCA _r	$1,0013 \cdot 10^5$	$9,5198 \cdot 10^4$	$9,7507 \cdot 10^4$	$9,7512 \cdot 10^4$	$1,1571 \cdot 10^3$
	GWO _r	$9,7581 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5993 \cdot 10^4$	$9,5864 \cdot 10^4$	$5,9340 \cdot 10^2$
	SCA _{xb}	$1,0147 \cdot 10^5$	$9,7763 \cdot 10^4$	$9,9585 \cdot 10^4$	$9,9689 \cdot 10^4$	$7,9099 \cdot 10^2$
	SCA _b	$9,7511 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5778 \cdot 10^4$	$9,5667 \cdot 10^4$	$5,7977 \cdot 10^2$
	GWO _b	$9,5727 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5314 \cdot 10^4$	$9,5198 \cdot 10^4$	$2,1085 \cdot 10^2$
	ACO	$9,5370 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5072 \cdot 10^4$	$9,5023 \cdot 10^4$	$1,1623 \cdot 10^2$
MB	SCA _{xr}	3660,4	3637,4	3648,9	3648,3	4,9673
	SCA _r	3624,5	3607,1	3614,7	3614,1	4,8841
	GWO _r	3612,2	3607,1	3608,1	3607,1	1,6492
	SCA _{xb}	3655,7	3630,4	3643,0	3644,0	5,7127
	SCA _b	3609,1	3607,1	3607,2	3607,1	0,4892
	GWO _b	3607,1	3607,1	3607,1	3607,1	0,0000
	ACO	3639,4	3614,9	3631,3	3630,8	4,7209
MC	SCA _{xr}	111,22	106,82	109,46	109,51	1,1926
	SCA _r	106,14	101,64	102,98	102,68	1,4776
	GWO _r	104,93	98,29	101,25	101,65	1,2831
	SCA _{xb}	106,13	101,79	103,94	103,89	1,1666
	SCA _b	101,98	99,89	101,56	101,64	0,4139
	GWO _b	101,66	99,03	100,90	101,64	0,8679
	ACO	99,01	97,31	97,90	97,31	0,7784
MD	SCA _{xr}	91755	91669	91723	91722	18,678
	SCA _r	91637	91637	91637	91637	0,000
	GWO _r	91637	91637	91637	91637	0,000
	SCA _{xb}	91682	91641	91660	91659	9,807
	SCA _b	91637	91637	91637	91637	0,000
	GWO _b	91637	91637	91637	91637	0,000
	ACO	91793	91699	91754	91758	23,120

Fonte: Elaborada pelo autor (2019).

As Tabela 25 exibe os resultados estatísticos obtidos, enquanto que a Tabela 26 relaciona as taxas percentuais de acerto de cada TIC em relação às melhores soluções obtidas em cada modalidade. Em comparação à Tabela 21 associada ao conjunto CS1, nota-se na Tabela 25 reduções significativas, com exceção do ACO, das melhores aptidões, médias, medianas e desvios-padrões (DP) obtidos por cada TIC, o que se deve basicamente ao fato de a busca ser realizada sempre na região viável. No caso do ACO, as melhoras foram sutis, o que evidencia o fato de que esta TIC ser altamente capaz de evitar regiões inviáveis, ou seja, a limitação à região viável não resulta em grande benefício para a mesma.

Nas modalidades MA e MC, assim como nas simulações do conjunto CS1, o ACO foi predominante. A aplicação dos limites provocou um aumento de 22% para 30% e

Tabela 26 – Taxas de acerto, em %, de cada TIC - CS2

	SCA_{xr}	SCA_r	GWO_r	SCA_{xb}	SCA_b	GWO_b	ACO
MA	0	0	2	0	2	2	30
MB	0	10	68	0	94	100	0
MC	0	0	0	0	0	0	52
MD	0	100	100	0	100	100	0

Fonte: Elaborada pelo autor (2019).

de 36% para 52% nas taxas de acerto nas referidas modalidades, respectivamente. O mesmo pode ser dito para o GWO_b nas modalidades MB e MD, em que as taxas de acerto foram de 32% e 48%, respectivamente, para 100% em ambos os casos, ou seja, a imposição de limites teve um grande impacto nestas modalidades de otimização. Além disso, ainda nas modalidades MB e MD, os algoritmos SCA_r, GWO_r e SCA_b, os quais tiveram aproveitamentos nulos sem a imposição de limites, passaram para 10%, 68% e 94% na modalidade MB e todos para 100% na modalidade MD.

É de fato esperado que os resultados melhorem com a imposição de limites, já que tal fator implica na certeza de que a busca será sempre realizada dentro da região viável de solução. Mesmo sem aumentar os números de indivíduos ou o de iterações, foi possível obter taxas de acerto de 100% nas modalidades MB e MD, o que significa que o GWO_b com imposição de limites poderia ser aplicado apenas com 30 indivíduos e 100 iterações em uma situação real, o que, com base na Tabela 23, exigiria menos de 2 segundos para efetuar a otimização. Para fins de comparação, simulações adicionais das modalidades MA e MC também com imposição de limites foram realizadas com 100 indivíduos e 300 iterações. As taxas de acerto encontram-se expostas na Tabela 27.

Tabela 27 – Taxas de acerto, em %, de cada TIC nas modalidades MA e MC com mais indivíduos e iterações - CS2

	SCA_{xr}	SCA_r	GWO_r	SCA_{xb}	SCA_b	GWO_b	ACO
MA	0	0	0	0	4	4	92
MC	0	0	2	0	0	0	100

Fonte: Elaborada pelo autor (2019).

Com base na Tabela 27 e nos dois parágrafos imediatamente anteriores, constata-se que, na modalidade MA, seria possível aplicar o ACO em uma otimização real utilizando-se 4 execuções e considerando-se a melhor solução como definitiva, o que resultaria em uma confiabilidade de 99,9959% e levaria menos de 1 minuto e 10 segundos para finalizar o processo. Na modalidade MC, poderia aplicar-se o ACO com 2 ou 3 execuções, como precaução, visto que neste caso a TIC em questão apresentou uma taxa de acerto de 100%. Tal decisão implicaria em menos de 50 segundos para efetuar a otimização.

Chegou-se, portanto, à conclusão que a TIC a ser efetivamente aplicada na otimização da operação da UHE estuda depende da modalidade escolhida. Caso o operador opte pelas modalidades MA ou MC, deve-se executar o ACO, enquanto que se a modalidade MB ou MD for selecionada, deve-se executar o GWOb. Embora o SCAb tenha fornecido excelentes resultados nestas modalidades com valores maiores de indivíduos e iterações e imposição de limites, o GWOb se mostrou mais consistente, visto que foi capaz de solucionar o problema mesmo com menos indivíduos e iterações.

4.2.4 Análise de Sensibilidade

Parâmetros como o número de indivíduos e de iterações melhoram a probabilidade de encontrar melhores soluções, pois tendem a aumentar a diversificação da população e permitem uma busca mais extensa, respectivamente. Porém, é intuitivo que acrescentar os valores de tais parâmetros resultará em melhores desempenhos a custo de tempo de execução. Portanto, não há neste trabalho a intenção de vastamente explorar resultados oriundos de variações destes. Em contrapartida, almeja-se analisar o impacto de se alterar parâmetros que afetem os mecanismos de deslocamento dos indivíduos nestas TICs.

Em relação aos algoritmos baseados no SCA e no GWO, variou-se o valor do coeficiente de exploração (a), o qual é o único parâmetro que afeta como a busca é realizada pelos indivíduos nestas TICs. Este parâmetro determina o módulo da distância a ser percorrida pelos indivíduos, ou seja, enquanto menor for, maiores as probabilidades de se locomoverem com menores deslocamentos e vice-versa. Na proposição do GWO (26), o coeficiente de exploração não é tratado como um parâmetro a ser ajustado, sendo considerado um termo fixo igual a 2. Em contrapartida, a proposição do SCA (61) trata este coeficiente como passível de alteração. Para fins investigativos, neste trabalho alterou-se o parâmetro a tanto no SCA quanto no GWO.

No ACO, variou-se o valor da taxa de evaporação (t_{eva}). Este parâmetro determina quanto os valores da matriz de feromônio irão ser decrescidos a cada iteração, ou seja, basicamente sua alteração afeta o quanto as informações de iterações anteriores são “carregadas” para as iterações seguintes. Tendo em vista que maiores valores de feromônio acarretam maiores probabilidades de um indivíduo assumir determinado valor dentro da região de solução, pode-se inferir que uma maior evaporação implica em menores probabilidades do indivíduo assimilar o valor da melhor solução encontrada até a iteração em questão, fazendo com que o algoritmo enfatize mais a exploração e menos a intensificação.

A fim de realizar uma breve análise de sensibilidade das TICs estudadas, foram estabelecidos mais 5 conjuntos de simulações denominados S1, S2, S3, S4 e S5, sendo que em cada um destes executou-se as 4 modalidades de otimização apresentadas. Os valores de a e t_{eva} utilizados encontram-se dispostos na Tabela 28. Aplicou-se os mesmos números de indivíduos e iterações das simulações iniciais, ou seja, 30 e 100, respectivamente, e

foram realizadas 50 simulações por modalidade para cada valor dos parâmetros. Além disso, assim como no conjunto CS1, considerou-se os limites inferiores e superiores iguais a 1 e 5, respectivamente, e aplicou-se a penalização da função objetivo (Equação 4.3), tornando assim o processo mais árduo. De modo a simplificar a análise, somente as taxas de acerto foram avaliadas, as quais encontram-se expostas na Tabela 29.

Tabela 28 – Parâmetros para análises de sensibilidade

	S1	S2	S3	S4	S5
a	0,5	1	1,5	2,5	3
t_{eva}	0	2	10	15	20

Fonte: Elaborada pelo autor (2019).

Tabela 29 – Taxas de acerto, em %, de cada TIC para análises de sensibilidade

		SCA_{xr}	SCA_r	GWO_r	SCA_{xb}	SCA_b	GWO_b	ACO
S1	MA	0	0	0	0	0	0	6
	MB	0	0	0	0	42	58	0
	MC	0	0	0	0	0	0	18
	MD	0	0	0	0	48	68	0
S2	MA	0	0	0	0	0	0	18
	MB	0	0	0	0	20	66	0
	MC	0	0	0	0	0	0	34
	MD	0	0	0	0	30	72	0
S3	MA	0	0	0	0	0	0	28
	MB	0	0	0	0	0	60	0
	MC	0	0	0	0	0	0	28
	MD	0	0	0	0	6	86	0
S4	MA	0	0	0	0	0	0	16
	MB	0	0	0	0	0	2	2
	MC	0	0	0	0	0	0	18
	MD	0	0	0	0	0	12	0
S5	MA	0	0	0	0	0	0	10
	MB	0	0	0	0	0	0	10
	MC	0	0	0	0	0	0	14
	MD	0	0	0	0	0	0	0

Fonte: Elaborada pelo autor (2019).

Ao se comparar a Tabela 22, a qual contém as taxas de acerto com a igual a 2 e t_{eva} igual a 5%, com a Tabela 29, as observações a seguir podem ser enunciadas:

- Independente dos valores dos parâmetros contidos na Tabela 28, nenhuma das variações do SCA ou do GWO foi capaz de fornecer a melhor solução encontrada

nas modalidades MA e MC;

- Ainda nas modalidades MA e MC, o ACO apresentou quedas de desempenho nas simulações S1, S4 e S5, enquanto que uma relativa constância em S3 e S4 em comparação aos resultados exibidos na Tabela 22, o que indica não ser ideal utilizar uma taxa de evaporação nula ou superior a 10% no problema abordado;
- O ACO não se mostrou eficiente nas modalidades MB e MD com quaisquer valores de t_{eva} testados, apresentando taxas de acerto nulas na maioria dos casos, sendo que, mesmo quando não nulas, estas são muito baixas;
- O SCAb, que não havia obtido a melhor solução possível em nenhuma simulação das modalidades MB e MD, apresentou na simulação S1 taxas de acerto superior e igual às obtidas pelo GWOb nas modalidades MB e MD, respectivamente (Tabela 22), enquanto que o desempenho desta TIC foi decrescente da simulação S2, na qual ainda houve obtenções das soluções ótimas, para a simulação S5, na qual a taxa de acerto foi nula. Tais fatores indicam que esta técnica se beneficia de valores significativamente baixos de a , ao menos no problema aqui estudado;
- O desempenho do GWOb foi consideravelmente superior nas simulações S1, S2 e S3 para as modalidades MB e MD, com ênfase na simulação S3 da modalidade MD em comparação ao exibido na Tabela 22, evidenciando que esta TIC realiza buscas mais eficientes com a entre 0,5 e 1,5, o que é enfatizado pelo fato de o desempenho ter sido precário nas simulações S4 e S5.

Embora as simulações com imposição de limites tenham resultado em uma certa garantia de obtenção da solução ótima nas modalidades MB e MD pelo GWOb (Tabela 26), a aplicação de um coeficiente de exploração adequado é de grande benefício em aplicações reais, visto que, na otimização da operação de uma UHE qualquer, pode ser que a quantidade de unidades geradoras seja maior que a da UHE aqui estudada, o que aumenta a região de busca, e que a discretização seja realizada em intervalos de tempo menores ao longo do dia, o que eleva o número de variáveis no problema, ou seja, a obtenção da solução ótima pela TIC aplicada pode ser dificultada em relação ao estudo de caso aqui apresentado, de acordo com as características da UHE a ser otimizada. Conclui-se que, além da possibilidade de aumento dos números de indivíduos e iterações, a utilização de um valor propício de a pode colaborar com o processo, sendo que, ao contrário da primeira medida, esta não aumenta o esforço computacional.

Ao leitor que desejar realizar uma análise mais profunda das consequências das variações dos parâmetros a e t_{eva} no problema em questão, informações adicionais podem ser consultadas no Apêndice B. Porém, em linhas gerais:

- O ACO, o qual teve desempenhos próximos com t_{eva} igual a 2%, 5% e 10% em relação às taxas de acerto, apresentou menores mediana e desvio-padrão com t_{eva} iguais a 10% e 5%, respectivamente, na modalidade MA e igual a 2% e 0, respectivamente, na modalidade MC. Porém, considerando a baixa taxa de acerto oriunda do valor nulo de t_{eva} , o segundo menor desvio-padrão na modalidade MC foi apresentado com t_{eva} igual a 2%. Ressalta-se, no entanto, que as diferenças notadas nestas medidas são de baixíssimas magnitudes e certamente não fariam diferença significativa na otimização, bastando-se aplicar um valor entre 2% e 10% para se obter bons resultados;
- O SCAB apresentou melhoras significativas nas modalidades MB e MD com a igual a 0,5 e, em menor proporção, 1 não só em relação às taxas de acerto, mas também às medianas e aos desvios-padrões, apesar de o GWOb ter apresentado melhor desempenho nestas modalidades;
- O GWOb, o qual obteve melhoras notáveis nas taxas de acerto nas modalidades MB e MD com a igual a 0,5, 1 e 1,5 em relação a a igual a 2, em especial na modalidade MD com a igual a 1,5, apresentou diferenças desprezíveis nas medianas em todos estes casos. Contudo, apesar de os valores 0,5 e 1 para a terem acarretado maiores desvios-padrões em relação ao valor 2, o valor 1,5 foi capaz de reduzi-los significativamente em ambas modalidades, o que mais uma vez indica que, entre os valores testados para o coeficiente de exploração, este é o ideal;
- Em relação ao SCAXr, SCAR, GWOr e SCAXb, os impactos das variações em a foram inconsistentes, talvez pelo fato de não serem adequadas para o tipo de problema, e, portanto, não permitiram que se chegasse a conclusões.

4.2.5 Resultados Hidrológicos e Operacionais

Ao final do processo de otimização da operação exposto na subseção anterior, o código desenvolvido fornece um relatório contendo as informações hidrológicas e operacionais da UHE. De acordo com a modalidade de operação, é exibido o planejamento ótimo a ser realizado, os quais foram mostrados nas Figuras 39, Figuras 40, Figuras 41, e Figuras 42 para as modalidades MA, MB, MC e MD, respectivamente. As Tabelas 30, 31, 32, e 33 exibem os números de unidades geradoras a operar (n), de partidas em relação ao período anterior (n_u), de paradas em relação ao período anterior (n_d), a potência gerada por cada unidade (P_{un}), a vazão turbinada unitária (q_{un}), a vazão turbinada total (q_{tot}) e a reserva girante (rg) por período para as modalidades MA, MB, MC e MD, respectivamente. Com fim de simplificação visual, períodos com resultados idênticos foram agrupados nas Tabelas 30 a 33. Enfatiza-se que, como o modelo matemático da UHE considera o nível do reservatório constante durante as simulações, para uma mesma quantidade de unidades atendendo um mesmo valor de demanda de potência as vazões serão idênticas. Tal simplificação é consequência da operação a fio d'água e implica em erros negligenciáveis nos resultados.

Tabela 30 – Resultados hidrológicos na modalidade MA

Per.	n	n_u	n_d	P_{un} (MW)	q_{un} (m ³ /s)	q_{tot} (m ³ /s)	rg (MW)
1	4	4	0	162,50	498,91	1995,65	73,99
2 a 4	4	0	0	162,50	498,91	1995,65	73,99
5	3	0	1	133,33	392,02	1176,06	144,16
6 a 17	3	0	0	100,00	294,67	884,02	244,16
18	5	2	0	130,00	400,04	2000,21	253,62
19 a 21	5	0	0	130,00	400,04	2000,21	253,62
22 a 35	5	0	0	170,00	545,70	2728,49	53,62
36 a 48	5	0	0	130,00	400,04	2000,21	253,62

Fonte: Elaborada pelo autor (2019).

Tabela 31 – Resultados hidrológicos na modalidade MB

Per.	n	n_u	n_d	P_{un} (MW)	q_{un} (m ³ /s)	q_{tot} (m ³ /s)	rg (MW)
1	5	5	0	130,00	400,04	2000,21	253,62
2 a 4	5	0	0	130,00	400,04	2000,21	253,62
5	3	0	2	133,33	392,02	1176,06	144,16
6	2	0	1	150,00	431,37	862,75	58,01
7 a 17	2	0	0	150,00	431,37	862,75	58,01
18	5	3	0	130,00	400,04	2000,21	253,62
19 a 21	5	0	0	130,00	400,04	2000,21	253,62
22 a 35	5	0	0	170,00	545,70	2728,49	53,62
36 a 48	5	0	0	130,00	400,04	2000,21	253,62

Fonte: Elaborada pelo autor (2019).

Tabela 32 – Resultados hidrológicos na modalidade MC

Per.	n	n_u	n_d	P_{un} (MW)	q_{un} (m ³ /s)	q_{tot} (m ³ /s)	rg (MW)
1	4	4	0	162,50	498,91	1995,65	73,99
2 a 4	4	0	0	162,50	498,91	1995,65	73,99
5	4	0	0	100,00	299,67	1198,69	323,99
6 a 17	4	0	0	75,00	227,98	911,93	423,99
18 a 21	4	0	0	162,50	498,91	1995,65	73,99
22	5	1	0	170,00	545,70	2728,49	53,62
23 a 35	5	0	0	170,00	545,70	2728,49	53,62
36 a 48	5	0	0	130,00	400,04	2000,21	253,62

Fonte: Elaborada pelo autor (2019).

Um aspecto interessante a se notar entre as Tabelas 31 e 33, as quais correspondem às modalidades MB e MD, ou seja, às minimizações das perdas definidas em (21; 23) e das vazões, respectivamente, é que enquanto na primeira planeja-se cinco unidades geradoras a operar entre os períodos 18 a 21 e 36 a 48, na segunda planeja-se quatro unidades

Tabela 33 – Resultados hidrológicos na modalidade MD

Per.	n	n_u	n_d	P_{un} (MW)	q_{un} (m ³ /s)	q_{tot} (m ³ /s)	rg (MW)
1	4	4	0	162,50	498,91	1995,65	73,99
2 a 4	4	0	0	162,50	498,91	1995,65	73,99
5	3	0	1	133,33	392,02	1176,06	144,16
6	2	0	1	150,00	431,37	862,75	58,01
7 a 17	2	0	0	150,00	431,37	862,75	58,01
18	4	2	0	162,50	498,91	1995,65	73,99
19 a 21	4	0	0	162,50	498,91	1995,65	73,99
22	5	1	0	170,00	545,70	2728,49	53,62
23 a 35	5	0	0	170,00	545,70	2728,49	53,62
36	4	0	1	162,50	498,91	1995,65	73,99
37 a 48	4	0	0	162,50	498,91	1995,65	73,99

Fonte: Elaborada pelo autor (2019).

geradoras em tais períodos. Tal fato é decorrente de, para a meta de geração de 650 MW atribuída aos referidos períodos, obter-se menos perdas com cinco unidades geradoras em operação, embora esta configuração de máquinas acarrete maior consumo de recursos hídricos. Como discutido na Seção 4.1, a minimização das perdas de potência definidas em (21; 23) não garantem a minimização da vazão turbinada pela usina. Estas diferenças nos planejamentos podem ser claramente vistas comparando-se as Figuras 40 e 42.

Embora somente a modalidade MA seja baseada no custo da operação ao longo do horizonte de programação da usina, calculou-se, para fins de análise, os custos operacionais (C_{ope}) das soluções ótimas de todas as modalidades utilizando-se os mesmos valores de c_{pp} e c_{per} aplicados à modalidade MA, ou seja, 500 u.a. e 50 u.a./MWh (Tabela 20), respectivamente. Além destes custos, calculou-se o volume total de água turbinada (Vol), os custos oriundos exclusivamente de partidas e paradas (C_{PP}), as quantidades de partidas ou paradas (Q_{PP}) e as perdas (Per) ao longo do horizonte de programação em cada modalidade. Estes resultados são exibidos na Tabela 34. Enfatiza-se que as perdas não são dadas pela definição clássica, ou seja, pela razão entre a potência de saída e a de entrada, sendo definidas conforme proposto em (21; 23) e exposto no Capítulo 3.

Nota-se na Tabela 34 que, como esperado, o menor custo é de fato fornecido na modalidade MA. Além disso, percebe-se também que as menores perdas, quantidades de partidas ou paradas e vazões foram obtidas nas modalidades MB, MC e MD, respectivamente. Os resultados estão, portanto, de acordo com as diretrizes estabelecidas.

Mais especificamente sobre a economia de recursos hídricos, há uma diferença de consumo de 1,12 hm³ de água no intervalo de 24 horas entre as modalidades MD, a qual minimiza a vazão turbinada, e MC, a qual minimiza partidas e paradas e ocasiona o maior consumo hídrico. Tal diferença pode escalar para valores ainda maiores ao se considerar

Tabela 34 – Resultados operacionais

	MA	MB	MC	MD
C_{ope} (u.a.)	94972	95677	95891	97913
Vol (hm ³)	165, 54	165, 12	166, 16	164, 95
C_{PP} (u.a.)	3500, 0	5500, 0	2500, 0	5000, 0
Q_{PP}	7	11	5	10
Per (MW)	3658, 9	3607, 1	3735, 7	3716, 5

Fonte: Elaborada pelo autor (2019).

períodos mais longos, como semanas ou meses. Portanto, realizar uma otimização visando a minimização de uso da água estocada no reservatório pode ser de grande importância, principalmente em períodos com escassez de precipitação pluviométrica, embora tal medida possa proporcionar custos mais elevados (aqui se refere ao custo imediato da operação, visto que tal cenário pode acarretar mais partidas e paradas de máquinas, embora, tendo em vista que a economia de água tem o potencial de evitar acionamentos de usinas térmicas, a longo prazo tem-se um custo menor). Por outro lado, como observado na Tabela 34, em situações com abundância de recursos a ponto de ocasionar vertimento, isto é, em que se possa desprezar os custos associados às perdas de potência, o menor custo é obtido ao se minimizar as ocorrências de partidas ou paradas, poupando assim as vidas úteis das máquinas.

5 CONCLUSÕES

Este trabalho apresentou um estudo da aplicação de técnicas de inteligência computacional no problema de otimização da operação diária de usinas hidrelétricas operadas a fio d'água e com unidades geradoras idênticas. Os algoritmos *Sine Cosine Algorithm* (SCA), *Grey Wolf Optimizer* (GWO) e *Ant Colony Optimization* (ACO) foram aplicados e analisados. Uma alteração na equação de atualização de posição dos indivíduos do SCA foi analisada e mostrou elevar a eficácia do algoritmo. Além disso, aplicou-se adaptações binárias do SCA e GWO, as quais, embora tenham sido obtidas através de diretrizes já consolidadas na literatura (utilização da função sigmoide), foram aplicadas de uma forma inexplorada até então. Mais especificamente sobre este último aspecto, dada a natureza discreta do problema abordado, adaptou-se as versões binárias dos algoritmos mencionados para que se tornassem propícias a problemas com variáveis de decisão inteiras, sendo que tal adaptação aplicada no GWO se mostrou particularmente eficaz na resolução de duas modalidades de operação apresentadas, as outras tendo sido eficientemente solucionadas via ACO. As técnicas de inteligência computacional se mostraram capazes de resolver o problema em tempos de execução viáveis para aplicação real e com elevada confiabilidade.

Exibiu-se uma adaptação do modelo matemático de usina hidrelétrica apresentado em (21; 23), a qual visa a economia máxima de recursos hídricos, o que é especialmente útil em períodos de baixa precipitação pluviométrica. Finalmente, propôs-se uma nova abordagem para realização de ajustes de curvas de eficiência de turbinas hidráulicas, a qual combina técnicas de clusterização, como o Fuzzy C-Means, e os algoritmos ANFIS e Extreme Learning ANFIS, baseados em redes neurais artificiais, com objetivo de obter uma “caixa preta” que forneça a eficiência das turbinas em função de valores de altura de queda líquida e vazão turbinada. Tal abordagem foi capaz de fornecer uma superfície suave e com erros significativamente baixos.

5.1 Trabalhos Futuros

Como estudos posteriores, existe a intenção de: (i) aplicar técnicas de inteligência computacional em modelos que considerem diversas usinas simultaneamente, especialmente usinas em cascata; (ii) aplicar tais técnicas em modelos que permitam a existência de unidades geradoras com características distintas e que considerem variações no nível do reservatório ao longo do horizonte de planejamento, tornando o problema mais complexo; (iii) avaliar outras técnicas de otimização baseadas em inteligência computacional no problema abordado, preferencialmente as que demonstraram ser bem sucedidas na literatura; (iv) aprimorar a aplicação de algoritmos binários em problemas discretos no sentido de evitar valores inviáveis mais eficientemente; (v) estudar, em profundidade, métodos para estimativa dos custos de partidas e paradas de máquinas em usinas hidrelétricas, possibilitando

assim a aplicação real de uma abordagem baseada em custos monetários; (vi) incorporar ao modelo restrições associadas às limitações operativas por conta de cronogramas de manutenção; (vii) testar outras técnicas de clusterização na separação de grupos para ajuste da curva de eficiência de turbinas hidráulicas e (viii) avaliar a aplicação de outras técnicas baseadas em redes neurais artificiais na obtenção da “caixa preta” responsável por modelar a eficiência das turbinas.

REFERÊNCIAS

- 1 MOROMISATO, German David Yagi. **Programação Dinâmica Aplicada ao Cálculo da Energia Firme de Usinas Hidrelétricas**. 2012. Dissertação (Mestrado) - Faculdade de Engenharia Eletrica, Universidade Federal de Juiz de Fora, Juiz de Fora, 2012. Disponível em: bit.ly/2JPzQAR. Acesso em: 8 mar. 2020.
- 2 ONS. Submódulo 7.2. Disponível em: bit.ly/3lUvgyK. Acesso em: 22 jun. 2020.
- 3 ONS. Submódulo 7.3. Disponível em: bit.ly/3kiv4cs. Acesso em: 22 jun. 2020.
- 4 ONS. Submódulo 8.1. Disponível em: bit.ly/34bgRIH. Acesso em: 22 jun. 2020.
- 5 ONS. Submódulo 26.2. Disponível em: bit.ly/357Pu1e. Acesso em: 22 jun. 2020.
- 6 PEREIRA, M. V. F. Optimal stochastic operations scheduling of large hydroelectric systems. **International Journal of Electrical Power & Energy Systems**, v. 11, n. 3, p. 161-169, 1989.
- 7 PIEKUTOWSKI, M. R.; LITWINOWICZ, T.; FROWD, R. Optimal short-term scheduling for a large-scale cascaded hydro system. **IEEE Transactions on Power systems**, v. 9, n. 2, p. 805-811, 1994.
- 8 PONRAJAH, R. A.; WITHERSPOON, J.; GALIANA, F. D. Systems to optimise conversion efficiencies at Ontario Hydro's hydroelectric plants. **IEEE Transactions on Power systems**, v. 13, n. 3, p. 1044-1050, 1998.
- 9 NILSSON, O.; SODER, L.; SJELVGREN, D. Integer modelling of spinning reserve requirements in short term scheduling of hydro systems. **IEEE Transactions on Power systems**, v. 13, n. 3, p. 959-964, 1998.
- 10 BRETON, M; HACHEM, s; HAMMADIA, A; A decomposition approach for the solution of the unit loading problem in hydroplants. **Automatica**, v. 38, n. 3, p. 477-485, 2002.
- 11 OHISHI, T.; SANTOS, E.; ARCE, A.; KADOWAKI, M.; CICOGNA, M.; SOARES, S. Comparison of two heuristic approaches to hydro unit commitment. In: **2005 IEEE Russia Power Tech**, p. 1-7, 2005.
- 12 BORTONI, E. C.; BASTOS, G. S.; SOUZA, L. E. Optimal load distribution between units in a power plant. **ISA transactions**, v. 46, n. 4, p. 533-539, 2007.
- 13 SOUSA, T.; JARDINI, J. A.; DE LIMA, R. A. Hydroelectric power plant unit efficiencies evaluation and unit commitment. In: **2007 IEEE Lausanne Power Tech** p. 1368-1373, 2007.
- 14 CHEN, P. H.; CHEN, L. M.; LIU, A.; CHEN, H. C. Application of particle swarm optimization to hydro generation scheduling. In **2009 International Conference on Energy and Environment Technology**, v. 1, p. 541-544, 2009.
- 15 FERNANDES, J. P. T.; DE BARROS CORREA, P.; HIDALGO, I. G.; COLNAGO, G. R. A genetic algorithm solution for optimization of the power generation potential in hydroelectric plants. In: **2013 IEEE Congress on Evolutionary Computation**. IEEE, p. 2504-2511, 2013.

- 16 FINARDI, E. C.; TAKIGAWA, F. Y. K.; BRITO, B. H. Assessing solution quality and computational performance in the hydro unit commitment problem considering different mathematical programming approaches. **Electric Power Systems Research**, v. 136, p. 212-222, 2016.
- 17 DAL'SANTO, T., & COSTA, A. S. (2016). Hydroelectric unit commitment for power plants composed of distinct groups of generating units. **Electric Power Systems Research**, 137, 16-25.
- 18 MING, B., LIU, P., GUO, S., CHENG, L., ZHOU, Y., GAO, S., & LI, H. (2018). Robust hydroelectric unit commitment considering integration of large-scale photovoltaic power: A case study in China. **Applied Energy**, 228, 1341-1352.
- 19 BRITO, B. H., FINARDI, E. C., & TAKIGAWA, F. Y. K. (2020). Mixed-integer nonseparable piecewise linear models for the hydropower production function in the Unit Commitment problem. **Electric Power Systems Research**, 182, 106234.
- 20 ONS. Submódulo 9.9. Disponível em: bit.ly/2zQYv34. Acesso em: 22 jun. 2020.
- 21 ARCE ENCINA, Anastacio Sebastian. **Despacho ótimo de unidades geradoras em sistemas hidrelétricos via heurística baseada em relaxação lagrangeana e programação dinâmica**. 2006. Tese (Doutorado) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2006. Disponível em: bit.ly/3p9GCKP. Acesso em: 5 jun. 2019.
- 22 MARCATO, André Luís Marques. Notas de aula - Planejamento da Operação e Expansão, Capítulo II - As Usinas Hidrelétricas. Disponível em: bit.ly/357DRsz. Acesso em: 08 ago. 2020.
- 23 ARCE ENCINA, Anastacio Sebastian. **Um modelo de otimização do despacho de máquinas em usinas hidrelétricas**. 1999. Dissertação (Mestrado) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1999. Disponível em: bit.ly/3k3TOnz. Acesso em: 25 jul. 2019.
- 24 CORDOVA, M. M.; FINARDI, E. C.; RIBAS, F. A. C.; DE MATOS, V. L.; SCUZZIATO, M. R. Performance evaluation and energy production optimization in the real-time operation of hydropower plants. **Electric Power Systems Research**, v. 116, p. 201-207, 2014.
- 25 CHAPMAN, S. **Electric Machinery Fundamentals**. Tata McGraw-Hill Education, 2005.
- 26 MIRJALILI, S.; MIRJALILI, S. M.; LEWIS, A. Grey wolf optimizer. **Advances in engineering software**, v. 69, p. 46-61, 2014.
- 27 HOLLAND, J. H. Genetic algorithms. **Scientific american**, v. 267, n. 1, p. 66-73, 1992.
- 28 STORN, R.; PRICE, K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. **Journal of global optimization**, v. 11, n. 4, p. 341-359, 1997.

- 29 KENNEDY, J.; EBERHART, R. Particle swarm optimization (PSO). In: **Proc. IEEE International Conference on Neural Networks**, Perth, Australia, p. 1942-1948, 1995.
- 30 DORIGO, M.; BIRATTARI, M.; STUTZLE, T. **Ant colony optimization**. in IEEE Computational Intelligence Magazine, v. 1, n. 4, p. 28-39, 2006.
- 31 RASHEDI, E.; NEZAMABADI-POUR, H.; SARYAZDI, S. GSA: a gravitational search algorithm. **Information sciences**, v. 179, n. 13, p. 2232-2248, 2009.
- 32 HATAMLLOU, A. Black hole: A new heuristic optimization approach for data clustering. **Information sciences**, v. 222, p. 175-184, 2013.
- 33 RECHENBERG, I. Evolution strategy: Nature's way of optimization. In: BERGMANN H.W. **Optimization: Methods and applications, possibilities and limitations**. Springer, Berlin, Heidelberg, p. 106-126, 1989.
- 34 HANSEN, N.; MÜLLER, S. D.; KOUMOUTSAKOS, P. Reducing the time complexity of the derandomized evolution strategy with covariance matrix adaptation (CMA-ES). **Evolutionary computation**, v. 11, n. 1, p. 1-18, 2003.
- 35 KOZA, John R.; KOZA, John R. **Genetic programming: on the programming of computers by means of natural selection**. MIT press, 1992.
- 36 FOGEL, D. B. **Artificial intelligence through simulated evolution**. Wiley-IEEE Press, 1998.
- 37 YAO, X.; LIU, Y.; LIN, G. Evolutionary programming made faster. **IEEE Transactions on Evolutionary computation**, v. 3, n. 2, p. 82-102, 1999.
- 38 SIMON, D. Biogeography-based optimization. **IEEE transactions on evolutionary computation**, v. 12, n. 6, p. 702-713, 2008.
- 39 WEBSTER, B.; BERNHARD, P. J. A local search optimization algorithm based on natural principles of gravitation. **Technical report #CS-2003-10**, 2003.
- 40 EROL, O. K.; EKSIN, I. A new optimization method: big bang–big crunch. **Advances in Engineering Software**, v. 37, n. 2, p. 106-111, 2006.
- 41 FORMATO, R. A. Central force optimization. **Progress in Electromagnetics Research**, v. 77, p. 425-491, 2007.
- 42 ALATAS, B. ACROA: artificial chemical reaction optimization algorithm for global optimization. **Expert Systems with Applications**, v. 38, n. 10, p. 13170-13180, 2011.
- 43 SHAH-HOSSEINI, H. Principal components analysis by the galaxy-based search algorithm: a novel metaheuristic for continuous optimisation. **International Journal of Computational Science and Engineering**, v. 6, n. 1-2, p. 132-140, 2011.
- 44 KARABOGA, D. An idea based on honey bee swarm for numerical optimization. **Technical report -tr06**, Erciyes university, engineering faculty, computer engineering department, 2005.

- 45 YANG, Xin-She. A new metaheuristic bat-inspired algorithm. In: GONZÁLEZ J.R., PELTA D.A., CRUZ C., TERRAZAS G., KRASNOGOR N. **Nature inspired cooperative strategies for optimization (NICSO 2010)**. Springer, Berlin, Heidelberg, p. 65-74, 2010.
- 46 PAN, W.-T. A new fruit fly optimization algorithm: taking the financial distress model as an example. **Knowledge-Based Systems**, v. 26, p. 69-74, 2012.
- 47 MIRJALILI, S.; LEWIS, A. The whale optimization algorithm. **Advances in engineering software**, v. 95, p. 51-67, 2016.
- 48 LI, Xiaolei., **A New Intelligent Optimization-Artificial Fish School Algorithm**. 2003. Tese (Doutorado) - Universidade de Zhejiang, Zhejiang, China, 2003.
- 49 MUCHERINO, A.; SEREF, O. Monkey search: a novel metaheuristic search for global optimization. In: **AIP conference proceedings**. AIP, p. 162-173, 2007.
- 50 YANG, X.-S.; DEB, S. Cuckoo search via Lévy flights. In: **2009 World Congress on Nature & Biologically Inspired Computing (NaBIC)**. IEEE, p. 210-214, 2009.
- 51 YANG, X.-S. Firefly algorithm, stochastic test functions and design optimisation. **arXiv preprint arXiv:1003.1409**, 2010.
- 52 LI, S.; FANG, H.; LIU, X. Parameter optimization of support vector regression based on sine cosine algorithm. **Expert systems with Applications**, v. 91, p. 63-77, 2018.
- 53 WANG, J.; YANG, W.; DU, P.; NIU, T. A novel hybrid forecasting system of wind speed based on a newly developed multi-objective sine cosine algorithm. **Energy Conversion and Management**, v. 163, p. 134-150, 2018.
- 54 ATTIA, A.-F.; EL SEHIEMY, R. A.; HASANIEN, H. M. Optimal power flow solution in power systems using a novel Sine-Cosine algorithm. **International Journal of Electrical Power & Energy Systems**, v. 99, p. 331-343, 2018.
- 55 MIRJALILI, S. How effective is the Grey Wolf optimizer in training multi-layer perceptrons. **Applied Intelligence**, v. 43, n. 1, p. 150-161, 2015.
- 56 MIRJALILI, S.; SAREMI, S.; MIRJALILI, S. M.; COELHO, L. D. S. Multi-objective grey wolf optimizer: a novel algorithm for multi-criterion optimization. **Expert Systems with Applications**, v. 47, p. 106-119, 2016.
- 57 JAYABARATHI, T.; RAGHUNATHAN, T.; ADARSH, B. R.; SUGANTHAN, P. N. Economic dispatch using hybrid grey wolf optimizer. **Energy**, v. 111, p. 630-641, 2016.
- 58 MARZBAND, M.; YOUSEFNEJAD, E.; SUMPER, A.; DOMÍNGUEZ-GARCÍA, J. L. Real time experimental implementation of optimum energy management system in standalone microgrid by using multi-layer ant colony optimization. **International Journal of Electrical Power & Energy Systems**, v. 75, p. 265-274, 2016.

- 59 SAMA, M.; PELLEGRINI, P.; D,ARIANO, A.; RODRIGUEZ, J.; PACCIARELLI, D. Ant colony optimization for the real-time train routing selection problem. **Transportation Research Part B: Methodological**, v. 85, p. 89-108, 2016.
- 60 DENG, W.; XU, J.; ZHAO, H. An improved ant colony optimization algorithm based on hybrid strategies for scheduling problem. **IEEE access**, v. 7, p. 20281-20292, 2019.
- 61 MIRJALILI, S. SCA: a sine cosine algorithm for solving optimization problems. **Knowledge-Based Systems**, v. 96, p. 120-133, 2016.
- 62 WOLPERT, D. H.; MACREADY, W. G. No free lunch theorems for optimization. **IEEE transactions on evolutionary computation**, v. 1, n. 1, p. 67-82, 1997.
- 63 DORIGO, M.; MANIEZZO, V.; COLORNI, A. Positive feedback as a search strategy. 1991.
- 64 DORIGO, Marco. **Optimization, learning and natural algorithms**. 1992. Tese (Doutorado) - Politecnico di Milano, 1992.
- 65 DORIGO, M.; MANIEZZO, V.; COLORNI, A. Ant system: optimization by a colony of cooperating agents. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, v. 26, n. 1, p. 29-41, 1996.
- 66 DORIGO, M.; DI CARO, G. Ant colony optimization: a new meta-heuristic. **Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)**, Washington, DC, USA, v. 2, p. 1470-1477, 1999.
- 67 Yarpiz (2020). Ant Colony Optimization (ACO) (mathworks.com/matlabcentral/fileexchange/52859-ant-colony-optimization-aco), MATLAB Central File Exchange. Acesso em: 2 jan.2020.
- 68 KHANESAR, M. A.; TESHNEHLAB, M.; SHOOREHDELI, M. A. A novel binary particle swarm optimization. In: **2007 Mediterranean Conference on Control & Automation**. IEEE, p. 1-6, 2007.
- 69 EMARY, E.; ZAWBAA, H. M.; HASSANIEN, A. E. Binary grey wolf optimization approaches for feature selection. **Neurocomputing**, v. 172, p. 371-381, 2016.
- 70 KASHAN, M. H.; NAHAVANDI, N.; KASHAN, A. H. DisABC: A new artificial bee colony algorithm for binary optimization. **Applied Soft Computing**, v. 12, n. 1, p. 342-352, 2012.
- 71 WANG, L.; ZHENG, X.-L.; WANG, S.-Y. A novel binary fruit fly optimization algorithm for solving the multidimensional knapsack problem. **Knowledge-Based Systems**, v. 48, p. 17-23, 2013.
- 72 MIRJALILI, S.; MIRJALILI, S. M.; YANG, X.-S. Binary bat algorithm. **Neural Computing and Applications**, v. 25, n. 3-4, p. 663-681, 2014.
- 73 HUSSIEN, A. G.; HOUSSEIN, E. H.; HASSANIEN, A. E. A binary whale optimization algorithm with hyperbolic tangent fitness function for feature selection. In: **2017 Eighth International Conference on Intelligent Computing and Information Systems (ICICIS)**. IEEE, p. 166-172, 2017.

- 74 HIDALGO, I. G.; SOARES, S.; FONTANE, D. G.; CICOGNA, M. A.; LOPES, J. E. G. Impact of the Data Quality from Hydroelectric Plants in the Past Operation Analysis using a Middle Term Simulation Tool. **International Multi-Conference on Engineering and Technological Innovation**, 2009.
- 75 HIDALGO, I. G.; FONTANE, D. G.; SOARES F., S.; CICOGNA, M. A.; LOPES, J. E. G. Data consolidation from hydroelectric plants. **Journal of Energy Engineering**, v. 136, n. 3, p. 87-94, 2010.
- 76 HIDALGO, I.; LOPES, J. E. G.; SOARES F., S.; CICOGNA, M.; FONTANE, D.; SILVA F., D. Analysis of the Level-Release Polynomial from a Hydroelectric Plant. **Systemic, Cybernetics and Informatics**, v. 10, n. 1, p. 62-65, 2012.
- 77 BEZDEK, J. C.; EHRLICH, R.; FULL, W. FCM: The fuzzy c-means clustering algorithm. **Computers & Geosciences**, v. 10, n. 2-3, p. 191-203, 1984.
- 78 JANG, J.-SR. ANFIS: adaptive-network-based fuzzy inference system. **IEEE transactions on systems, man, and cybernetics**, v. 23, n. 3, p. 665-685, 1993.
- 79 PILLAI, G. N. Extreme anfis: A new learning machine for faster learning. In: **International conference on knowledge collaboration in engineering**, Coimbatore, 2014.
- 80 RAFFE, W.; HU, J.; ZAMBETTA, F.; XI, K. A dual-layer clustering scheme for real-time identification of plagiarized massive multiplayer games (MMG) assets. In: **2010 5th IEEE Conference on Industrial Electronics and Applications**. IEEE, p. 307-312, 2010.
- 81 RAMIREZ-ROZO, T. J.; GARCIA-ALVAREZ, J. C.; CASTELLANOS-DOMINGUEZ, C. G. Infrared thermal image segmentation using expectation-maximization-based clustering. In: **2012 XVII Symposium of Image, Signal Processing, and Artificial Vision (STSIVA)**. IEEE, p. 223-226, 2012.
- 82 RIBBENS, A.; HERMANS, J.; MAES, F.; VANDERMEULEN, D.; SUETENS, P. Unsupervised segmentation, clustering, and groupwise registration of heterogeneous populations of brain MR images. **IEEE transactions on medical imaging**, v. 33, n. 2, p. 201-224, 2013.
- 83 TSAI, C.-F.; HUANG, S.-C. An effective and efficient grid-based data clustering algorithm using intuitive neighbor relationship for data mining. In: **2015 International Conference on Machine Learning and Cybernetics (ICMLC)**. IEEE, p. 478-483, 2015.
- 84 EROL, H.; TYODEN, B. M.; EROL, R. Classification performances of data mining clustering algorithms for remotely sensed multispectral image data. In: **2018 Innovations in Intelligent Systems and Applications (INISTA)**. IEEE, p. 1-4, 2018.
- 85 XIE, W.; XIE, Z.; ZHAO, F.; REN, B. POLSAR Image Classification via Clustering-WAE Classification Model. **IEEE Access**, v. 6, p. 40041-40049, 2018.
- 86 KRISHNAPURAM, R.; KELLER, J. M. A possibilistic approach to clustering. **IEEE transactions on fuzzy systems**, v. 1, n. 2, p. 98-110, 1993.

- 87 YANG, M.-S.; KO, C.-H. On a class of fuzzy c-numbers clustering procedures for fuzzy data. **Fuzzy sets and systems**, v. 84, n. 1, p. 49-60, 1996.
- 88 PAL, N. R.; PAL, K.; BEZDEK, J. C. A mixed c-means clustering model. In: **Proceedings of 6th international fuzzy systems conference**. IEEE, p. 11-21, 1997.
- 89 MIYAMOTO, Sadaaki; UYAHARA, Kazutaka. Methods in hard and fuzzy clustering. In: LIU Z. Q., MIYAMOTO S. **Soft computing and human-centered machines**. Springer, Tokyo, p. 85-129, 2000.
- 90 HUNG, M.-C.; YANG, D.-L. An efficient fuzzy c-means clustering algorithm. In: **Proceedings 2001 IEEE International Conference on Data Mining**. IEEE, p. 225-232, 2001.
- 91 RHEE, F. C.-H.; HWANG, C. A type-2 fuzzy C-means clustering algorithm. In: **Proceedings Joint 9th IFSA World Congress and 20th NAFIPS International Conference (Cat. No. 01TH8569)**. IEEE, p. 1926-1929, 2001.
- 92 PAL, N. R.; PAL, K.; KELLER, J. M.; BEZDEK, J. C. A possibilistic fuzzy c-means clustering algorithm. **IEEE transactions on fuzzy systems**, v. 13, n. 4, p. 517-530, 2005.
- 93 HORE, P.; HALL, L. O.; GOLDFOG, D. B. Single pass fuzzy c means. In: **2007 IEEE International Fuzzy Systems Conference**. IEEE, p. 1-7, 2007.
- 94 ZARANDI, M. H. F.; ZARINBAL, M.; TÜRKSEN, I. B. Type-II Fuzzy Possibilistic C-Mean Clustering. In: **IFSA/EUSFLAT Conf**. Citeseer, p. 30-35, 2009.
- 95 HAVENS, T. C.; BEZDEK, J. C.; LECKIE, C.; HALL, L. O.; PALANISWAMI, M. Fuzzy c-means algorithms for very large data. **IEEE Transactions on Fuzzy Systems**, v. 20, n. 6, p. 1130-1146, 2012.
- 96 PARKER, J. K.; HALL, L. O. Accelerating fuzzy-c means using an estimated subsample size. **IEEE Transactions on Fuzzy Systems**, v. 22, n. 5, p. 1229-1244, 2013.
- 97 RUBIO, E.; CASTILLO, O.; MELIN, P. A new interval type-2 fuzzy possibilistic C-means clustering algorithm. In: **2015 Annual Conference of the North American Fuzzy Information Processing Society (NAFIPS) held jointly with 2015 5th World Conference on Soft Computing (WConSC)**. IEEE, p. 1-5, 2015.
- 98 ALAM, I.; ANSARI, M. A.; PAL, N. S. A comparative study between wavelet primarily based ANN and ANFIS algorithm technique to locate fault in a transmission line. In: **2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)**. IEEE, p. 1-6, 2016.
- 99 CIVICIOGLU, P. Using uncorrupted neighborhoods of the pixels for impulsive noise suppression with ANFIS. **IEEE Transactions on Image Processing**, v. 16, n. 3, p. 759-773, 2007.

- 100 CAO, H.; SI, G.; ZHANG, Y.; MA, X. A hybrid controller of self-optimizing algorithm and ANFIS for ball mill pulverizing system. In: **2007 International Conference on Mechatronics and Automation**. IEEE, p. 3289-3294, 2007.
- 101 HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: theory and applications. **Neurocomputing**, v. 70, n. 1-3, p. 489-501, 2006.
- 102 CAO, J.-J.; KWONG, S.; WANG, R.; LI, K. A weighted voting method using minimum square error based on Extreme Learning Machine. In: **2012 International Conference on Machine Learning and Cybernetics**. IEEE, p. 411-414, 2012.
- 103 ZHENG, R.; PAN, F. Soft sensor of glutamate concentration using extreme learning machine. In: **Proceeding of the 11th World Congress on Intelligent Control and Automation**. IEEE, p. 1865-1868, 2014.
- 104 SÖNMEZ, Y.; TUNCER, T.; GÖKAL, H.; AVCI, E. Phishing web sites features classification based on extreme learning machine. In: **2018 6th International Symposium on Digital Forensic and Security (ISDFS)**. IEEE, p. 1-5, 2018.
- 105 HOSSAIN, M. S.; MUHAMMAD, G. Emotion recognition using deep learning approach from audio-visual emotional big data. **Information Fusion**, v. 49, p. 69-78, 2019.
- 106 CAO, J.; LIN, Z.; HUANG, G.-B.; LIU, N. Voting based extreme learning machine. **Information Sciences**, v. 185, n. 1, p. 66-77, 2012.
- 107 JAGTAP, P.; PILLAI, G. N. Comparison of extreme-ANFIS and ANFIS networks for regression problems. In: **2014 IEEE International Advance Computing Conference (IACC)**. IEEE, p. 1190-1194, 2014.
- 108 SHIHABUDHEEN, K. V.; PILLAI, G. N. Internal model control based on extreme learning ANFIS for nonlinear application. In: **2015 IEEE International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES)**. IEEE, p. 1-5, 2015.
- 109 TUSHAR, A.; ABHINAV; PILLAI, G. N. Extreme Learning ANFIS for classification problems. In: **2015 1st International Conference on Next Generation Computing Technologies (NGCT)**. IEEE, p. 784-787, 2015.
- 110 NHABANGUE, M. F. C; PILLAI, G. N.; SHARMA, M. L. Chaotic time series prediction with functional link extreme learning ANFIS (FL-ELANFIS). In: **2018 International Conference on Power, Instrumentation, Control and Computing (PICC)**. IEEE, p. 1-6, 2018.
- 111 NILSSON, O.; SJELVGREN, D. Hydro unit start-up costs and their impact on the short term scheduling strategies of Swedish power producers. **IEEE Transactions on power systems**, v. 12, n. 1, p. 38-44, 1997.
- 112 NILSSON, O.; SJELVGREN, D. Variable splitting applied to modelling of start-up costs in short term hydro generation scheduling. **IEEE Transactions on Power Systems**, v. 12, n. 2, p. 770-775, 1997.

APÊNDICE A – Parâmetros de Modelagem da Curva Colina

Com exceção dos dados da CET da UHE estuda, todos os dados da usina foram disponibilizados na subseção 4.2.1. De modo a possibilitar a reprodução dos resultados obtidos e expostos na Seção 4.2, este apêndice descreve as linhas de código em linguagem MATLAB® para que se obtenha as informações do modelo da CET.

O Código A.1 estabelece a estrutura (CCU) que define a CET. Para cálculo da eficiência das turbinas nas Equações 3.3 a 3.7 do Algoritmo 4, deve-se utilizar o arquivo de simulação do Extreme ANFIS disponível no link fornecido na subseção 3.2.3 em conjunto com CCU, conforme Código A.2, em que “nt”, “hql” e “q” representam, respectivamente, a eficiência da turbina, a altura de queda líquida e a vazão turbinada unitária, sendo “hql” calculada na Equação 3.2 e “q” calculado conforme passo 1.a) do Algoritmo 4.

Código A.1 – Estrutura do modelo da CET da UHE estuda.

```
CCU.con.consequent = [3.212664 0.310701 -53.16560; 0.050539 -0.008840 88.95087
0.075541 0.019449 84.38985; 0.133118 0.007850 86.37924
0.336387 -0.006380 87.46870; 0.397363 -0.019740 94.76354
0.911802 0.281857 21.64974; 0.196940 0.086509 64.26955
0.187961 0.025272 78.36330; 0.282765 -0.011920 91.46087
0.209383 -0.012570 94.44993; 0.427857 -0.025430 98.37632
-0.719170 0.002809 92.49983; 0.204045 0.018981 83.25522
0.225993 0.022227 81.56373; 0.136110 0.016385 83.11278
0.265431 0.003654 83.24716; 0.234181 -0.008690 91.21454
0.459749 0.082289 51.49052; 0.249785 0.048959 75.29181
0.058960 0.051093 77.83177; 0.014246 0.044593 72.98816
0.224460 0.012163 78.26155; 0.063486 -0.001110 90.59169
0.476412 0.090609 49.72463; -0.202710 0.057176 88.09512
0.017270 0.045926 80.44141; 0.068342 0.037599 74.45315
0.022485 0.005195 89.05814; 0.169481 -0.011410 94.62512
0.715455 0.089198 41.18971; -0.098330 0.062101 83.02437
-0.018390 0.036354 84.01139; 0.001573 0.021300 84.46440
0.101240 -0.000610 90.06639; 0.144066 -0.006300 91.98737];
```

```
CCU.c = [20.51752 25.07059 28.76999 31.08682 34.05094 39.25215
49.67436 176.2861 308.4157 437.3755 581.5278 721.5247];
```

```
CCU.a = [2.832239 0.81656 1.204602 1.746122 0.629812 1.816235
111.1078 66.0340 119.0771 90.19395 104.9113 51.28751];
```

```
CCU.b = [1.986851 1.95191 2.048237 2.006677 2.075118 2.078735
1.976953 2.03200 1.973426 2.065412 2.082449 1.976546];
```

Código A.2 – Cálculo de eficiência das turbinas.

```
nt=simextremeanfis([hql q],CCU)/100;
```


APÊNDICE B – Informações Estatísticas Adicionais

Tabela 35 – Resultados estatísticos das aptidões - S1

		Pior	Melhor	Média	Mediana	DP
MA	SCA _{xr}	$5,0884 \cdot 10^6$	$3,5924 \cdot 10^6$	$4,4742 \cdot 10^6$	$4,5831 \cdot 10^6$	$3,2159 \cdot 10^5$
	SCA _r	$5,0730 \cdot 10^6$	$2,3522 \cdot 10^6$	$3,8595 \cdot 10^6$	$3,9577 \cdot 10^6$	$5,0790 \cdot 10^5$
	GWO _r	$4,3145 \cdot 10^6$	$2,0825 \cdot 10^6$	$2,9141 \cdot 10^6$	$2,8309 \cdot 10^6$	$4,6111 \cdot 10^5$
	SCA _{xb}	$4,0875 \cdot 10^6$	$2,3518 \cdot 10^6$	$3,3835 \cdot 10^6$	$3,3468 \cdot 10^6$	$4,0119 \cdot 10^5$
	SCA _b	$5,9431 \cdot 10^5$	$9,5262 \cdot 10^4$	$2,2585 \cdot 10^5$	$9,7702 \cdot 10^4$	$1,5261 \cdot 10^5$
	GWO _b	$5,9277 \cdot 10^5$	$9,5248 \cdot 10^4$	$1,8591 \cdot 10^5$	$9,6949 \cdot 10^4$	$1,4838 \cdot 10^5$
	ACO	$9,5921 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5403 \cdot 10^4$	$9,5396 \cdot 10^4$	$2,3441 \cdot 10^2$
MB	SCA _{xr}	$2,0174 \cdot 10^5$	$1,5206 \cdot 10^5$	$1,7752 \cdot 10^5$	$1,8178 \cdot 10^5$	$1,3435 \cdot 10^4$
	SCA _r	$1,9161 \cdot 10^5$	$1,1251 \cdot 10^5$	$1,5645 \cdot 10^5$	$1,6186 \cdot 10^5$	$1,6627 \cdot 10^4$
	GWO _r	$1,6208 \cdot 10^5$	$7,2729 \cdot 10^4$	$1,1688 \cdot 10^5$	$1,1237 \cdot 10^5$	$1,9433 \cdot 10^4$
	SCA _{xb}	$1,6204 \cdot 10^5$	$9,2915 \cdot 10^4$	$1,3611 \cdot 10^5$	$1,3245 \cdot 10^5$	$1,4656 \cdot 10^4$
	SCA _b	$2,3337 \cdot 10^4$	$3,6071 \cdot 10^3$	$7,7515 \cdot 10^3$	$3,6096 \cdot 10^3$	$5,3066 \cdot 10^3$
	GWO _b	$3,3267 \cdot 10^4$	$3,6071 \cdot 10^3$	$8,3454 \cdot 10^3$	$3,6071 \cdot 10^3$	$8,2801 \cdot 10^3$
	ACO	$3,6441 \cdot 10^3$	$3,6227 \cdot 10^3$	$3,6344 \cdot 10^3$	$3,6351 \cdot 10^3$	$4,9920 \cdot 10^0$
MC	SCA _{xr}	$4,0032 \cdot 10^5$	$2,8029 \cdot 10^5$	$3,4131 \cdot 10^5$	$3,4032 \cdot 10^5$	$2,5898 \cdot 10^4$
	SCA _r	$2,9024 \cdot 10^5$	$1,0015 \cdot 10^5$	$2,0141 \cdot 10^5$	$2,0521 \cdot 10^5$	$4,5625 \cdot 10^4$
	GWO _r	$1,4016 \cdot 10^5$	$1,0180 \cdot 10^2$	$5,2933 \cdot 10^4$	$5,0132 \cdot 10^4$	$3,0921 \cdot 10^4$
	SCA _{xb}	$3,4034 \cdot 10^5$	$1,8027 \cdot 10^5$	$2,7909 \cdot 10^5$	$2,8029 \cdot 10^5$	$3,7470 \cdot 10^4$
	SCA _b	$4,0124 \cdot 10^4$	$1,0164 \cdot 10^2$	$1,4315 \cdot 10^4$	$1,0115 \cdot 10^4$	$1,0903 \cdot 10^4$
	GWO _b	$4,0119 \cdot 10^4$	$9,9920 \cdot 10^1$	$7,9081 \cdot 10^3$	$1,0636 \cdot 10^2$	$1,0165 \cdot 10^4$
	ACO	$1,0023 \cdot 10^2$	$9,7314 \cdot 10^1$	$9,8279 \cdot 10^1$	$9,8016 \cdot 10^1$	$9,0777 \cdot 10^{-1}$
MD	SCA _{xr}	$2,5445 \cdot 10^5$	$1,9831 \cdot 10^5$	$2,2784 \cdot 10^5$	$2,2889 \cdot 10^5$	$1,1364 \cdot 10^4$
	SCA _r	$2,2879 \cdot 10^5$	$1,8183 \cdot 10^5$	$2,0712 \cdot 10^5$	$2,0812 \cdot 10^5$	$1,2275 \cdot 10^4$
	GWO _r	$2,0624 \cdot 10^5$	$1,4981 \cdot 10^5$	$1,7766 \cdot 10^5$	$1,8000 \cdot 10^5$	$1,4200 \cdot 10^4$
	SCA _{xb}	$2,1448 \cdot 10^5$	$1,6856 \cdot 10^5$	$1,9350 \cdot 10^5$	$1,9293 \cdot 10^5$	$1,2222 \cdot 10^4$
	SCA _b	$1,2146 \cdot 10^5$	$9,1637 \cdot 10^4$	$9,4564 \cdot 10^4$	$9,1641 \cdot 10^4$	$5,1664 \cdot 10^3$
	GWO _b	$1,0618 \cdot 10^5$	$9,1637 \cdot 10^4$	$9,4255 \cdot 10^4$	$9,1637 \cdot 10^4$	$4,5892 \cdot 10^3$
	ACO	$9,1983 \cdot 10^4$	$9,1813 \cdot 10^4$	$9,1909 \cdot 10^4$	$9,1912 \cdot 10^4$	$3,5922 \cdot 10^1$

Fonte: Elaborada pelo autor (2019).

Tabela 36 – Resultados estatísticos das aptidões - S2

		Pior	Melhor	Média	Mediana	DP
MA	SCA_{xr}	$5,3351 \cdot 10^6$	$3,8417 \cdot 10^6$	$4,6099 \cdot 10^6$	$4,5923 \cdot 10^6$	$3,3622 \cdot 10^5$
	SCA_r	$4,8198 \cdot 10^6$	$2,0930 \cdot 10^6$	$3,6646 \cdot 10^6$	$3,8286 \cdot 10^6$	$6,0933 \cdot 10^5$
	GWOr	$3,0821 \cdot 10^6$	$1,0941 \cdot 10^6$	$2,1034 \cdot 10^6$	$2,0922 \cdot 10^6$	$4,7023 \cdot 10^5$
	SCA_{xb}	$3,5854 \cdot 10^6$	$1,6116 \cdot 10^6$	$2,6828 \cdot 10^6$	$2,8430 \cdot 10^6$	$4,0575 \cdot 10^5$
	SCA_b	$8,4413 \cdot 10^5$	$9,5860 \cdot 10^4$	$3,0608 \cdot 10^5$	$3,4421 \cdot 10^5$	$2,3159 \cdot 10^5$
	GWOb	$3,4713 \cdot 10^5$	$9,5198 \cdot 10^4$	$1,4112 \cdot 10^5$	$9,6479 \cdot 10^4$	$9,6590 \cdot 10^4$
	ACO	$9,5765 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5233 \cdot 10^4$	$9,5176 \cdot 10^4$	$1,9403 \cdot 10^2$
MB	SCA_{xr}	$2,1167 \cdot 10^5$	$1,6203 \cdot 10^5$	$1,8592 \cdot 10^5$	$1,8691 \cdot 10^5$	$1,1678 \cdot 10^4$
	SCA_r	$1,8195 \cdot 10^5$	$9,2624 \cdot 10^4$	$1,4516 \cdot 10^5$	$1,5210 \cdot 10^5$	$2,2030 \cdot 10^4$
	GWOr	$1,4204 \cdot 10^5$	$6,2802 \cdot 10^4$	$9,3930 \cdot 10^4$	$9,2586 \cdot 10^4$	$1,8523 \cdot 10^4$
	SCA_{xb}	$1,4215 \cdot 10^5$	$8,2876 \cdot 10^4$	$1,1234 \cdot 10^5$	$1,1250 \cdot 10^5$	$1,3322 \cdot 10^4$
	SCA_b	$2,3404 \cdot 10^4$	$3,6071 \cdot 10^3$	$7,7564 \cdot 10^3$	$3,6155 \cdot 10^3$	$6,0123 \cdot 10^3$
	GWOb	$2,3337 \cdot 10^4$	$3,6071 \cdot 10^3$	$6,5695 \cdot 10^3$	$3,6071 \cdot 10^3$	$5,7276 \cdot 10^3$
	ACO	$3,6455 \cdot 10^3$	$3,6200 \cdot 10^3$	$3,6317 \cdot 10^3$	$3,6308 \cdot 10^3$	$5,0126 \cdot 10^0$
MC	SCA_{xr}	$4,1035 \cdot 10^5$	$3,2030 \cdot 10^5$	$3,7112 \cdot 10^5$	$3,7032 \cdot 10^5$	$2,7622 \cdot 10^4$
	SCA_r	$2,9024 \cdot 10^5$	$9,0169 \cdot 10^4$	$2,1902 \cdot 10^5$	$2,2522 \cdot 10^5$	$4,6469 \cdot 10^4$
	GWOr	$8,0143 \cdot 10^4$	$1,0188 \cdot 10^2$	$1,5314 \cdot 10^4$	$1,0115 \cdot 10^4$	$1,9307 \cdot 10^4$
	SCA_{xb}	$3,3033 \cdot 10^5$	$1,6022 \cdot 10^5$	$2,3767 \cdot 10^5$	$2,3027 \cdot 10^5$	$4,2437 \cdot 10^4$
	SCA_b	$6,0147 \cdot 10^4$	$1,0164 \cdot 10^2$	$1,9320 \cdot 10^4$	$2,0121 \cdot 10^4$	$1,6280 \cdot 10^4$
	GWOb	$3,0123 \cdot 10^4$	$1,0009 \cdot 10^2$	$6,5077 \cdot 10^3$	$1,0389 \cdot 10^2$	$8,9875 \cdot 10^3$
	ACO	$1,0104 \cdot 10^2$	$9,7314 \cdot 10^1$	$9,8113 \cdot 10^1$	$9,7545 \cdot 10^1$	$9,5884 \cdot 10^{-1}$
MD	SCA_{xr}	$2,4897 \cdot 10^5$	$2,0120 \cdot 10^5$	$2,3233 \cdot 10^5$	$2,3185 \cdot 10^5$	$1,0584 \cdot 10^4$
	SCA_r	$2,2766 \cdot 10^5$	$1,6091 \cdot 10^5$	$2,0370 \cdot 10^5$	$2,0606 \cdot 10^5$	$1,4212 \cdot 10^4$
	GWOr	$1,8910 \cdot 10^5$	$1,2802 \cdot 10^5$	$1,6081 \cdot 10^5$	$1,6385 \cdot 10^5$	$1,3166 \cdot 10^4$
	SCA_{xb}	$1,9839 \cdot 10^5$	$1,5249 \cdot 10^5$	$1,7320 \cdot 10^5$	$1,7525 \cdot 10^5$	$9,6641 \cdot 10^3$
	SCA_b	$1,0618 \cdot 10^5$	$9,1637 \cdot 10^4$	$9,4995 \cdot 10^4$	$9,1660 \cdot 10^4$	$4,6907 \cdot 10^3$
	GWOb	$9,8908 \cdot 10^4$	$9,1637 \cdot 10^4$	$9,3237 \cdot 10^4$	$9,1637 \cdot 10^4$	$3,0426 \cdot 10^3$
	ACO	$9,1928 \cdot 10^4$	$9,1775 \cdot 10^4$	$9,1859 \cdot 10^4$	$9,1855 \cdot 10^4$	$3,4610 \cdot 10^1$

Fonte: Elaborada pelo autor (2019).

Tabela 37 – Resultados estatísticos das aptidões - S3

		Pior	Melhor	Média	Mediana	DP
MA	SCA _{xr}	$5,3288 \cdot 10^6$	$3,8512 \cdot 10^6$	$4,5779 \cdot 10^6$	$4,5903 \cdot 10^6$	$3,0575 \cdot 10^5$
	SCA _r	$4,5776 \cdot 10^6$	$2,6039 \cdot 10^6$	$3,6426 \cdot 10^6$	$3,5905 \cdot 10^6$	$4,6615 \cdot 10^5$
	GWO _r	$3,0795 \cdot 10^6$	$8,4215 \cdot 10^5$	$1,9306 \cdot 10^6$	$1,8469 \cdot 10^6$	$5,1040 \cdot 10^5$
	SCA _{xb}	$3,5923 \cdot 10^6$	$2,1106 \cdot 10^6$	$2,8861 \cdot 10^6$	$2,8470 \cdot 10^6$	$3,3325 \cdot 10^5$
	SCA _b	$1,5902 \cdot 10^6$	$9,7060 \cdot 10^4$	$5,2161 \cdot 10^5$	$5,9544 \cdot 10^5$	$3,4821 \cdot 10^5$
	GWO _b	$5,9430 \cdot 10^5$	$9,5198 \cdot 10^4$	$1,9090 \cdot 10^5$	$9,6867 \cdot 10^4$	$1,4112 \cdot 10^5$
	ACO	$9,5842 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5161 \cdot 10^4$	$9,5135 \cdot 10^4$	$1,8311 \cdot 10^2$
MB	SCA _{xr}	$2,0196 \cdot 10^5$	$1,6217 \cdot 10^5$	$1,8459 \cdot 10^5$	$1,8227 \cdot 10^5$	$1,2117 \cdot 10^4$
	SCA _r	$1,8172 \cdot 10^5$	$9,2614 \cdot 10^4$	$1,4104 \cdot 10^5$	$1,4212 \cdot 10^5$	$1,9054 \cdot 10^4$
	GWO _r	$1,3212 \cdot 10^5$	$3,3227 \cdot 10^4$	$8,0469 \cdot 10^4$	$8,2598 \cdot 10^4$	$2,2093 \cdot 10^4$
	SCA _{xb}	$1,3248 \cdot 10^5$	$9,2557 \cdot 10^4$	$1,1530 \cdot 10^5$	$1,1749 \cdot 10^5$	$1,1666 \cdot 10^4$
	SCA _b	$3,3222 \cdot 10^4$	$3,6123 \cdot 10^3$	$1,3292 \cdot 10^4$	$1,3491 \cdot 10^4$	$8,0923 \cdot 10^3$
	GWO _b	$1,3479 \cdot 10^4$	$3,6071 \cdot 10^3$	$5,5813 \cdot 10^3$	$3,6071 \cdot 10^3$	$3,9861 \cdot 10^3$
	ACO	$3,6305 \cdot 10^3$	$3,6122 \cdot 10^3$	$3,6210 \cdot 10^3$	$3,6219 \cdot 10^3$	$4,4842 \cdot 10^0$
MC	SCA _{xr}	$4,4034 \cdot 10^5$	$2,8027 \cdot 10^5$	$3,7672 \cdot 10^5$	$3,8033 \cdot 10^5$	$3,5161 \cdot 10^4$
	SCA _r	$3,1027 \cdot 10^5$	$1,4020 \cdot 10^5$	$2,2623 \cdot 10^5$	$2,2023 \cdot 10^5$	$4,9089 \cdot 10^4$
	GWO _r	$9,0147 \cdot 10^4$	$1,0070 \cdot 10^2$	$2,0518 \cdot 10^4$	$1,0117 \cdot 10^4$	$2,4419 \cdot 10^4$
	SCA _{xb}	$3,7033 \cdot 10^5$	$1,8024 \cdot 10^5$	$2,4668 \cdot 10^5$	$2,4027 \cdot 10^5$	$4,7692 \cdot 10^4$
	SCA _b	$1,0017 \cdot 10^5$	$1,0784 \cdot 10^2$	$3,5333 \cdot 10^4$	$3,5131 \cdot 10^4$	$2,1130 \cdot 10^4$
	GWO _b	$5,0143 \cdot 10^4$	$1,0164 \cdot 10^2$	$9,7096 \cdot 10^3$	$5,1077 \cdot 10^3$	$1,2619 \cdot 10^4$
	ACO	$1,0105 \cdot 10^2$	$9,7314 \cdot 10^1$	$9,8338 \cdot 10^1$	$9,7743 \cdot 10^1$	$1,1259 \cdot 10^0$
MD	SCA _{xr}	$2,5292 \cdot 10^5$	$2,0993 \cdot 10^5$	$2,3319 \cdot 10^5$	$2,3441 \cdot 10^5$	$1,1127 \cdot 10^4$
	SCA _r	$2,3760 \cdot 10^5$	$1,5481 \cdot 10^5$	$1,9948 \cdot 10^5$	$1,9907 \cdot 10^5$	$1,7227 \cdot 10^4$
	GWO _r	$1,8983 \cdot 10^5$	$1,2152 \cdot 10^5$	$1,5163 \cdot 10^5$	$1,5092 \cdot 10^5$	$1,6272 \cdot 10^4$
	SCA _{xb}	$2,0083 \cdot 10^5$	$1,5042 \cdot 10^5$	$1,7872 \cdot 10^5$	$1,7704 \cdot 10^5$	$1,1319 \cdot 10^4$
	SCA _b	$1,1419 \cdot 10^5$	$9,1637 \cdot 10^4$	$9,6942 \cdot 10^4$	$9,5337 \cdot 10^4$	$6,4402 \cdot 10^3$
	GWO _b	$9,8931 \cdot 10^4$	$9,1637 \cdot 10^4$	$9,2365 \cdot 10^4$	$9,1637 \cdot 10^4$	$2,2049 \cdot 10^3$
	ACO	$9,1852 \cdot 10^4$	$9,1725 \cdot 10^4$	$9,1788 \cdot 10^4$	$9,1784 \cdot 10^4$	$2,8028 \cdot 10^1$

Fonte: Elaborada pelo autor (2019).

Tabela 38 – Resultados estatísticos das aptidões - S4

		Pior	Melhor	Média	Mediana	DP
MA	SCA_{xr}	$5,3336 \cdot 10^6$	$3,5987 \cdot 10^6$	$4,5262 \cdot 10^6$	$4,5924 \cdot 10^6$	$3,1220 \cdot 10^5$
	SCA_r	$4,3355 \cdot 10^6$	$2,8349 \cdot 10^6$	$3,5472 \cdot 10^6$	$3,5912 \cdot 10^6$	$4,1236 \cdot 10^5$
	GWO_r	$2,8573 \cdot 10^6$	$8,4895 \cdot 10^5$	$1,9140 \cdot 10^6$	$2,0862 \cdot 10^6$	$5,1198 \cdot 10^5$
	SCA_{xb}	$3,5936 \cdot 10^6$	$2,5944 \cdot 10^6$	$3,1588 \cdot 10^6$	$3,3350 \cdot 10^6$	$3,1166 \cdot 10^5$
	SCA_b	$1,3491 \cdot 10^6$	$1,0193 \cdot 10^5$	$7,9241 \cdot 10^5$	$8,4505 \cdot 10^5$	$3,1064 \cdot 10^5$
	GWO_b	$8,4840 \cdot 10^5$	$9,6118 \cdot 10^4$	$1,7389 \cdot 10^5$	$9,9966 \cdot 10^4$	$1,4449 \cdot 10^5$
	ACO	$9,5500 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5216 \cdot 10^4$	$9,5248 \cdot 10^4$	$1,7010 \cdot 10^2$
MB	SCA_{xr}	$2,1184 \cdot 10^5$	$1,4260 \cdot 10^5$	$1,7929 \cdot 10^5$	$1,8203 \cdot 10^5$	$1,4567 \cdot 10^4$
	SCA_r	$1,8193 \cdot 10^5$	$1,0258 \cdot 10^5$	$1,4266 \cdot 10^5$	$1,4232 \cdot 10^5$	$2,0482 \cdot 10^4$
	GWO_r	$1,2233 \cdot 10^5$	$3,3238 \cdot 10^4$	$8,3137 \cdot 10^4$	$8,2739 \cdot 10^4$	$1,8952 \cdot 10^4$
	SCA_{xb}	$1,5223 \cdot 10^5$	$9,2570 \cdot 10^4$	$1,2422 \cdot 10^5$	$1,2259 \cdot 10^5$	$1,3656 \cdot 10^4$
	SCA_b	$6,2924 \cdot 10^4$	$3,6247 \cdot 10^3$	$2,7350 \cdot 10^4$	$2,3417 \cdot 10^4$	$1,3532 \cdot 10^4$
	GWO_b	$3,3272 \cdot 10^4$	$3,6071 \cdot 10^3$	$8,5623 \cdot 10^3$	$3,6440 \cdot 10^3$	$6,6887 \cdot 10^3$
	ACO	$3,6279 \cdot 10^3$	$3,6071 \cdot 10^3$	$3,6173 \cdot 10^3$	$3,6175 \cdot 10^3$	$3,5101 \cdot 10^0$
MC	SCA_{xr}	$4,3034 \cdot 10^5$	$3,2030 \cdot 10^5$	$3,8092 \cdot 10^5$	$3,8032 \cdot 10^5$	$2,9106 \cdot 10^4$
	SCA_r	$3,3024 \cdot 10^5$	$1,5020 \cdot 10^5$	$2,5084 \cdot 10^5$	$2,5025 \cdot 10^5$	$3,8630 \cdot 10^4$
	GWO_r	$1,0015 \cdot 10^5$	$1,0791 \cdot 10^2$	$3,5933 \cdot 10^4$	$3,0135 \cdot 10^4$	$2,4927 \cdot 10^4$
	SCA_{xb}	$3,6034 \cdot 10^5$	$1,7024 \cdot 10^5$	$2,6008 \cdot 10^5$	$2,6029 \cdot 10^5$	$4,4212 \cdot 10^4$
	SCA_b	$1,4020 \cdot 10^5$	$1,0510 \cdot 10^2$	$6,4759 \cdot 10^4$	$6,0168 \cdot 10^4$	$2,6835 \cdot 10^4$
	GWO_b	$5,0145 \cdot 10^4$	$1,0014 \cdot 10^2$	$1,3717 \cdot 10^4$	$1,0116 \cdot 10^4$	$1,5096 \cdot 10^4$
	ACO	$1,0288 \cdot 10^2$	$9,7314 \cdot 10^1$	$9,8760 \cdot 10^1$	$9,8960 \cdot 10^1$	$1,3052 \cdot 10^0$
MD	SCA_{xr}	$2,5294 \cdot 10^5$	$1,9346 \cdot 10^5$	$2,3135 \cdot 10^5$	$2,3321 \cdot 10^5$	$1,2395 \cdot 10^4$
	SCA_r	$2,3663 \cdot 10^5$	$1,7406 \cdot 10^5$	$2,0504 \cdot 10^5$	$2,0684 \cdot 10^5$	$1,4356 \cdot 10^4$
	GWO_r	$1,8928 \cdot 10^5$	$1,2807 \cdot 10^5$	$1,5161 \cdot 10^5$	$1,5181 \cdot 10^5$	$1,3475 \cdot 10^4$
	SCA_{xb}	$2,1428 \cdot 10^5$	$1,5976 \cdot 10^5$	$1,8178 \cdot 10^5$	$1,8230 \cdot 10^5$	$1,0865 \cdot 10^4$
	SCA_b	$1,2888 \cdot 10^5$	$9,1754 \cdot 10^4$	$1,0793 \cdot 10^5$	$1,0645 \cdot 10^5$	$9,7195 \cdot 10^3$
	GWO_b	$1,0618 \cdot 10^5$	$9,1637 \cdot 10^4$	$9,3423 \cdot 10^4$	$9,1693 \cdot 10^4$	$3,4537 \cdot 10^3$
	ACO	$9,1826 \cdot 10^4$	$9,1720 \cdot 10^4$	$9,1771 \cdot 10^4$	$9,1767 \cdot 10^4$	$2,8027 \cdot 10^1$

Fonte: Elaborada pelo autor (2019).

Tabela 39 – Resultados estatísticos das aptidões - S5

		Pior	Melhor	Média	Mediana	DP
MA	SCA _{xr}	$4,8519 \cdot 10^6$	$3,3575 \cdot 10^6$	$4,4325 \cdot 10^6$	$4,3554 \cdot 10^6$	$2,9496 \cdot 10^5$
	SCA _r	$4,5849 \cdot 10^6$	$2,5876 \cdot 10^6$	$3,5156 \cdot 10^6$	$3,5942 \cdot 10^6$	$4,3596 \cdot 10^5$
	GWO _r	$2,8475 \cdot 10^6$	$1,0932 \cdot 10^6$	$1,9909 \cdot 10^6$	$2,0916 \cdot 10^6$	$4,7626 \cdot 10^5$
	SCA _{xb}	$4,3398 \cdot 10^6$	$2,3529 \cdot 10^6$	$3,2584 \cdot 10^6$	$3,3395 \cdot 10^6$	$3,9626 \cdot 10^5$
	SCA _b	$2,0866 \cdot 10^6$	$3,5260 \cdot 10^5$	$1,0905 \cdot 10^6$	$1,0953 \cdot 10^6$	$3,5945 \cdot 10^5$
	GWO _b	$1,0939 \cdot 10^6$	$9,9214 \cdot 10^4$	$3,5934 \cdot 10^5$	$3,4947 \cdot 10^5$	$2,4577 \cdot 10^5$
	ACO	$9,5631 \cdot 10^4$	$9,4972 \cdot 10^4$	$9,5274 \cdot 10^4$	$9,5360 \cdot 10^4$	$1,5937 \cdot 10^2$
MB	SCA _{xr}	$1,9209 \cdot 10^5$	$1,5235 \cdot 10^5$	$1,7712 \cdot 10^5$	$1,7722 \cdot 10^5$	$1,0619 \cdot 10^4$
	SCA _r	$1,7210 \cdot 10^5$	$1,0254 \cdot 10^5$	$1,3795 \cdot 10^5$	$1,4211 \cdot 10^5$	$1,6169 \cdot 10^4$
	GWO _r	$1,2242 \cdot 10^5$	$4,3130 \cdot 10^4$	$8,2006 \cdot 10^4$	$8,2868 \cdot 10^4$	$1,8195 \cdot 10^4$
	SCA _{xb}	$1,5218 \cdot 10^5$	$1,0262 \cdot 10^5$	$1,2639 \cdot 10^5$	$1,2746 \cdot 10^5$	$1,5459 \cdot 10^4$
	SCA _b	$7,2773 \cdot 10^4$	$3,6868 \cdot 10^3$	$3,8232 \cdot 10^4$	$3,8236 \cdot 10^4$	$1,5347 \cdot 10^4$
	GWO _b	$2,3420 \cdot 10^4$	$3,6342 \cdot 10^3$	$8,9793 \cdot 10^3$	$3,6651 \cdot 10^3$	$6,6757 \cdot 10^3$
	ACO	$3,6247 \cdot 10^3$	$3,6071 \cdot 10^3$	$3,6145 \cdot 10^3$	$3,6133 \cdot 10^3$	$4,4640 \cdot 10^0$
MC	SCA _{xr}	$4,3033 \cdot 10^5$	$2,9026 \cdot 10^5$	$3,8331 \cdot 10^5$	$3,9033 \cdot 10^5$	$2,9305 \cdot 10^4$
	SCA _r	$3,6029 \cdot 10^5$	$1,6021 \cdot 10^5$	$2,4965 \cdot 10^5$	$2,5025 \cdot 10^5$	$4,2170 \cdot 10^4$
	GWO _r	$1,3017 \cdot 10^5$	$1,1005 \cdot 10^2$	$5,8951 \cdot 10^4$	$5,5150 \cdot 10^4$	$2,7240 \cdot 10^4$
	SCA _{xb}	$3,6033 \cdot 10^5$	$1,6024 \cdot 10^5$	$2,5708 \cdot 10^5$	$2,6029 \cdot 10^5$	$3,8268 \cdot 10^4$
	SCA _b	$1,5024 \cdot 10^5$	$2,0121 \cdot 10^4$	$7,5571 \cdot 10^4$	$7,5166 \cdot 10^4$	$3,5029 \cdot 10^4$
	GWO _b	$7,0158 \cdot 10^4$	$1,0600 \cdot 10^2$	$2,1326 \cdot 10^4$	$2,0124 \cdot 10^4$	$1,7929 \cdot 10^4$
	ACO	$1,0118 \cdot 10^2$	$9,7314 \cdot 10^1$	$9,8892 \cdot 10^1$	$9,9104 \cdot 10^1$	$1,1979 \cdot 10^0$
MD	SCA _{xr}	$2,4763 \cdot 10^5$	$2,0304 \cdot 10^5$	$2,2869 \cdot 10^5$	$2,3104 \cdot 10^5$	$1,0522 \cdot 10^4$
	SCA _r	$2,2674 \cdot 10^5$	$1,7005 \cdot 10^5$	$1,9801 \cdot 10^5$	$1,9780 \cdot 10^5$	$1,2555 \cdot 10^4$
	GWO _r	$1,8319 \cdot 10^5$	$1,2176 \cdot 10^5$	$1,5369 \cdot 10^5$	$1,5191 \cdot 10^5$	$1,4109 \cdot 10^4$
	SCA _{xb}	$2,0634 \cdot 10^5$	$1,6372 \cdot 10^5$	$1,8482 \cdot 10^5$	$1,8500 \cdot 10^5$	$1,0249 \cdot 10^4$
	SCA _b	$1,3629 \cdot 10^5$	$9,9100 \cdot 10^4$	$1,1723 \cdot 10^5$	$1,1486 \cdot 10^5$	$1,1245 \cdot 10^4$
	GWO _b	$1,0701 \cdot 10^5$	$9,1682 \cdot 10^4$	$9,6185 \cdot 10^4$	$9,5457 \cdot 10^4$	$4,9137 \cdot 10^3$
	ACO	$9,1844 \cdot 10^4$	$9,1711 \cdot 10^4$	$9,1766 \cdot 10^4$	$9,1766 \cdot 10^4$	$2,9557 \cdot 10^1$

Fonte: Elaborada pelo autor (2019).

ANEXO A – Direitos Autorais ACO Yarpiz

Copyright (c) 2015, Yarpiz (www.yarpiz.com). All rights reserved. Redistribution and use in source and binary forms, with or without modification, are permitted provided that the following conditions are met: - Redistributions of source code must retain the above copyright notice, this list of conditions and the following disclaimer. - Redistributions in binary form must reproduce the above copyright notice, this list of conditions and the following disclaimer in the documentation and/or other materials provided with the distribution. THIS SOFTWARE IS PROVIDED BY THE COPYRIGHT HOLDERS AND CONTRIBUTORS “AS IS” AND ANY EXPRESS OR IMPLIED WARRANTIES, INCLUDING, BUT NOT LIMITED TO, THE IMPLIED WARRANTIES OF MERCHANTABILITY AND FITNESS FOR A PARTICULAR PURPOSE ARE DISCLAIMED. IN NO EVENT SHALL THE COPYRIGHT OWNER OR CONTRIBUTORS BE LIABLE FOR ANY DIRECT, INDIRECT, INCIDENTAL, SPECIAL, EXEMPLARY, OR CONSEQUENTIAL DAMAGES (INCLUDING, BUT NOT LIMITED TO, PROCUREMENT OF SUBSTITUTE GOODS OR SERVICES; LOSS OF USE, DATA, OR PROFITS; OR BUSINESS INTERRUPTION) HOWEVER CAUSED AND ON ANY THEORY OF LIABILITY, WHETHER IN CONTRACT, STRICT LIABILITY, OR TORT (INCLUDING NEGLIGENCE OR OTHERWISE) ARISING IN ANY WAY OUT OF THE USE OF THIS SOFTWARE, EVEN IF ADVISED OF THE POSSIBILITY OF SUCH DAMAGE.