



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE ENGENHARIA ELÉTRICA

FILIFE DIÓGENES BEZERRA COSTA

**PROPOSIÇÃO E IMPLEMENTAÇÃO DE UM CONTROLADOR DE CARGAS
INTELIGENTE CONSIDERANDO CUSTO ENERGÉTICO E CONFORTO BASEADO EM
ALGORITMOS GENÉTICOS**

FORTALEZA

2019

FILIPPE DIÓGENES BEZERRA COSTA

**PROPOSIÇÃO E IMPLEMENTAÇÃO DE UM CONTROLADOR DE CARGAS
INTELIGENTE CONSIDERANDO CUSTO ENERGÉTICO E CONFORTO
BASEADO EM ALGORITIMOS GENÉTICOS**

Monografia apresentada ao Curso de Engenharia Elétrica do Departamento de Engenharia Elétrica da Universidade Federal do Ceará, como requisito parcial à obtenção do Título de Graduação em Engenharia Elétrica.

Orientador: Ph.D. Fernando Luiz Marcelo Antunes

FORTALEZA

2019

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

C872p Costa, Filipe Diógenes Bezerra.
Proposição e implementação de um controlador de cargas inteligente considerando custo energético e conforto baseado em algoritmos genéticos / Filipe Diógenes Bezerra Costa. – 2019.
64 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Elétrica, Fortaleza, 2019.
Orientação: Prof. Dr. Fernando Luiz Marcelo Antunes.

1. Algoritmo Genético. 2. Otimização. 3. Frente de Pareto. 4. Hipervolume. I. Título.

CDD 621.3

**PROPOSIÇÃO E IMPLEMENTAÇÃO DE UM CONTROLADOR DE CARGAS
INTELIGENTE CONSIDERANDO CUSTO ENERGÉTICO E CONFORTO
BASEADO EM ALGORITIMOS GENÉTICOS**

Monografia apresentada ao Curso de Engenharia Elétrica do Departamento de Engenharia Elétrica da Universidade Federal do Ceará, como requisito parcial à obtenção do Título de Graduação em Engenharia Elétrica.

Aprovada em: ___/___/_____.

BANCA EXAMINADORA

Prof. Ph. D. Fernando Luiz Marcelo Antunes

Eng.º Felipe Carvalho Sampaio

Eng.^a Andresa Kelly Ribeiro Sombra

AGRADECIMENTOS

Ao Prof. PhD. Fernando Luiz Marcelo Antunes, pela orientação de maneira extremamente atenciosa. Aos participantes da minha banca examinadora Eng.º Felipe Sampaio e Eng.^a Andresa Sombra pela disponibilidade e atenção. Aos meus familiares e amigos pelo apoio e auxílio.

RESUMO

Existe uma demanda para a otimização de processos ineficientes que geram custo adicional. Este trabalho apresenta a proposição e implementação de um código, através de um controlador de cargas, baseado em algoritmo genético. A escolha desse algoritmo evolucionário é dada pela necessidade de resolver um problema de otimização multiobjetivo, para a maximização da economia e a maximização do conforto através do remanejamento das cargas de uma residência. A abordagem é focada na análise dos indicadores de tempo de execução do código e do hipervolume resultante das soluções. Este hipervolume é gerado através da proximidade da Frente de Pareto, obtida pelas distâncias entre as soluções e o ponto considerado ótimo. Para a composição do código foi utilizado um cenário de cargas em que os horários podem ser modificados, sendo a primeira geração composta por cenários previamente selecionados para facilitar a convergência. Estes cenários têm suas aptidões testadas através das funções objetivo para economia e conforto. É utilizado o *Pareto Envelope-based Selection Algorithm II (PESA II)* para gerar a Frente de Pareto. O código é executado em diversas configurações de geração e repetidas vezes com o intuito de encontrar melhores respostas entre esses cenários. Os resultados das simulações mostram grande evolução no acréscimo de gerações, conferindo maior estabilidade e melhores resultados. O diferencial da metodologia utilizada está em entender melhor o impacto das entradas e saídas do algoritmo e seu desempenho, visto que se trata de um código de busca de soluções com vários elementos de aleatoriedade e dependente da variedade de suas soluções.

Palavras-chave: Algoritmo Genético. Otimização. Frente de Pareto. Hipervolume.

ABSTRACT

There is a demand for optimization of inefficient processes that generate additional costs. The present work presents a proposition and implementation of a code, through a charge controller, based on genetic algorithm. The selection of this evolutionary algorithm is due to the need of resolving a multiobjective optimization problem, in order to maximize economy and comfort through relocation of charges in a house. The approach used focus on the analysis of time of code execution and the solutions' resulting hypervolume indicators. This hypervolume is generated through Pareto's Front, obtained by the distances between the solutions and what is considered a great point. A scenery of charges in which the times can be modified was used to compose the code, the first generation being made of previously selected scenarios to facilitate the convergence. These scenarios have their skills tested by the goal functions for economy and comfort. The *Pareto Envelope-based Selection Algorithm II (PESA II)* is utilized to generate Pareto's Front. The code is executed in various generations settings, and several times, with the intent to find the best answers between those scenarios. The simulations results show great evolution on the increasing of generations, granting more stability and better results. What sets the methodology apart is the better understanding of the impact of the algorithm's inputs and outputs and its performance, since it's a code in search of solutions, with many randomness elements and dependent of the variety of its solutions.

Palavras-chave: *Genetic Algorithm. Optimization. Pareto's Front. Hypervolume.*

LISTA DE FIGURAS

Figura 1 – Número de pesquisas sobre Smart Home.....	17
Figura 2 – Espaço de soluções para os parâmetros dos eixos X e Y.....	19
Figura 3 – Fluxograma de um Algoritmo Genético de estado estacionário.....	21
Figura 4 – Fluxograma do tomador de decisão.....	21
Figura 5 – Melhor valor e valor Médio da Função Aptidão em cada geração.....	27
Figura 6 – Desempenho com AG com Elitismo e sem Elitismo.....	27
Figura 7 – Fronteira de Pareto.....	29
Figura 8 – Hipercaixas no espaço de soluções.....	30
Figura 9 – Ilustração do hipervolume.....	31
Figura 10 – Arquitetura do sistema SHC.....	34
Figura 11 – Arquitetura da plataforma de testes.....	34
Figura 12 – Duração e horário de acionamento das cargas.....	39
Figura 13 – Interface web – SHC.....	62

LISTA DE TABELAS

Tabela 1 – Geração equivalente invertida.....	24
Tabela 2 – Comparação PESA e PESA-II.....	30
Tabela 3 – Parâmetros das Funções Objetivo.....	36
Tabela 4 – Tabela completa de resultados.....	43
Tabela 5 – Resultados para 10 repetições.....	44
Tabela 6 – Resultados para 30 repetições.....	46
Tabela 7 – Resultados para 70 repetições.....	47
Tabela 8 – Resultados para 150 repetições.....	49
Tabela 9 – Resultados para 300 repetições.....	50
Tabela 10 – Resultados para 1 geração.....	52
Tabela 11 – Resultados para 5 gerações.....	53
Tabela 12 – Resultados para 10 gerações.....	54
Tabela 13 – Resultados para 20 gerações.....	56
Tabela 14 – Resultados para 40 gerações.....	57
Tabela 15 – Resultados para 80 gerações.....	58

LISTA DE GRÁFICOS

Gráfico 1 – Código 10x – Geração x Tempo.....	45
Gráfico 2 – Código 10x – Geração x Hipervolume.....	45
Gráfico 3 – Código 30x – Geração x Tempo.....	46
Gráfico 4 – Código 30x – Geração x Hipervolume.....	47
Gráfico 5 – Código 70x – Geração x Tempo.....	48
Gráfico 6 – Código 70x – Geração x Hipervolume.....	48
Gráfico 7 – Código 150x – Geração x Tempo.....	49
Gráfico 8 – Código 150x – Geração x Hipervolume.....	50
Gráfico 9 – Código 300x – Geração x Tempo.....	50
Gráfico 10 – Código 300x – Geração x Hipervolume.....	51
Gráfico 11 – Código 1 Geração – Repetição x Tempo.....	52
Gráfico 12 – Código 1 Geração – Repetição x Hipervolume.....	53
Gráfico 13 – Código 5 Gerações – Repetição x Tempo.....	53
Gráfico 14 – Código 5 Gerações – Repetição x Hipervolume.....	54
Gráfico 15 – Código 10 Gerações – Repetição x Tempo.....	55
Gráfico 16 – Código 10 Gerações – Repetição x Hipervolume.....	55
Gráfico 17 – Código 20 Gerações – Repetição x Tempo.....	56
Gráfico 18 – Código 20 Gerações – Repetição x Hipervolume.....	56
Gráfico 19 – Código 40 Gerações – Repetição x Tempo.....	57
Gráfico 20 – Código 40 Gerações – Repetição x Hipervolume.....	58
Gráfico 21 – Código 80 Gerações – Repetição x Tempo.....	59
Gráfico 22 – Código 80 Gerações – Repetição x Hipervolume.....	59
Gráfico 23 – Arranjo de cargas sem otimização.....	60
Gráfico 24 – Arranjo de cargas com otimização.....	60

LISTA DE QUADROS

Quadro 1 – Pseudocódigo de um AG simples.....	23
Quadro 2 – Arquivo com as características.....	40
Quadro 3 – Pseudocódigo do PESA II.....	41
Quadro 4 – Estrutura de Medição.....	42

LISTA DE ABREVIATURAS E SIGLAS

TE	Tarifa de Energia
TUST	Tarifa de Uso do Sistema de Transição
TUSD	Tarifa de Uso do Sistema de Distribuição
ANEEL	Agência Nacional de Energia Elétrica
CDE	Conta de Desenvolvimento Energético
PROINFA	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
CFURH	Compensação Financeira pela Utilização de Recursos Hídricos
EER	Rácio de Eficiência Energética
TFSEE	Taxa de Fiscalização dos Serviços de Energia Elétrica
PEE	Programa de Eficiência Energética
ONS	Operador Nacional do Sistema
PIS	Programa Integração Social
COFINS	Contribuição para o Financiamento da Seguridade Social
ICMS	Imposto sobre Circulação de Mercadorias e Serviços
COSIP	Contribuição para o Custeio do Serviço de Iluminação Pública
AG	Algoritmo Genético
PESA	<i>Pareto Envelope-based Selection Algorithm</i>
EA	<i>Evolutionary Algorithms</i>
MOO	<i>Multi-Objective Optimization</i>
MOGA	<i>Multi-Objective Genetic Algorithm</i>
SHC	<i>Smart Home Controller</i>
IHM	Interface Homem-Máquina
CL	<i>Controllable Loads</i>
DL	<i>Detectable Loads</i>
SM	<i>Smart Meter</i>
SP	<i>Smart Plug</i>
CLP	Controlador Lógico Programável
ABNT	Associação Brasileira de Normas Técnicas

SUMÁRIO

1. Introdução.....	13
1.1 Contextualização do Problema.....	13
1.2 Objetivos.....	13
1.3 Estrutura do Trabalho.....	14
2. Fundamentação Teórica.....	15
2.1 Tarifas de Energia.....	15
2.2 Conforto e Economia.....	16
2.3 Smart Home.....	17
2.4 Controladores.....	18
3. Metaheurística Multiobjetivo.....	19
3.1 Algoritmo Genético.....	20
3.2 Pareto Envelope-based Selection Algorithm (PESA).....	29
3.3 Métricas.....	31
3.3.1 Hipervolume.....	31
3.3.2 Tempo.....	32
4. Estrutura do Código.....	33
4.1 Arquitetura.....	33
4.2 Lógica de Funcionamento do Código.....	35
4.2.1 Funções Objetivo.....	35
4.2.1.1 Custo com Energia Elétrica.....	36
4.2.1.2 Conforto.....	38
4.2.2 Cenário.....	39
4.2.3 Cenário PESA II.....	40
4.2.4 Aplicação da Métrica.....	41
5. Resultados.....	43
5.1 Análise por Acréscimo de Gerações.....	44
5.2 Análise por Acréscimo de Repetições.....	51
6. Conclusão.....	61
6.1 Trabalhos Futuros.....	62
REFERÊNCIAS.....	63

CAPÍTULO 1

1. Introdução

Neste capítulo serão apresentados, de forma resumida, a contextualização do problema trabalhado, os objetivos do trabalho proposto e a estrutura adotada neste trabalho.

1.1 Contextualização do problema

Há um crescimento da demanda por energia elétrica, provocada pela evolução das tecnologias que proporcionam conforto, pela ascensão econômica das pessoas e por uma própria cultura de utilização ininterrupta de energia elétrica que vem se consolidando a cada ano que passa.

As agências reguladoras de energia elétrica, juntamente com as concessionárias, para sustentar o balanço de energia ativa e reativa e demanda durante o dia, vem tornando em muitos países, de maneira obrigatória, a utilização da modalidade de tarifa de “ponta e fora de ponta”, que impõe custos adicionais de tarifa aos clientes que utilizam majoritariamente energia elétrica durante o horário considerado de ponta.

Esse curso leva a um gasto excessivo e crescente a medida que o uso de energia elétrica vai aumentando, portanto, é necessário haver um equilíbrio entre conforto ao utilizar as cargas, e economia ao pagar a conta de energia.

1.2 Objetivos

- **Objetivo Geral**

O objetivo deste trabalho é propor uma otimização multiobjetivo em algoritmo genético para obter a maximização do conforto e a maximização da economia para um mesmo cenário de cargas, considerando diferentes horários para cada carga durante o dia.

- **Objetivo Específico**

O trabalho se propõe a encontrar o melhor cenário de aplicação do algoritmo, considerando o número de vezes que o código é executado e quantas gerações são

utilizadas em uma única execução. Desta forma, aplicar de maneira mais assertiva o método utilizado.

1.3 Estrutura do Trabalho

A estrutura do trabalho após este capítulo introdutório é: no Capítulo 2 são apresentados e desenvolvidos temas relacionados com o estudo, para melhor compreensão e entendimento da problemática e de como se desenvolve a solução; no Capítulo 3 são mostradas as estruturas de otimização, e suas características, que serão utilizadas; no Capítulo 4 é mostrada a arquitetura e um estudo sobre os métodos de otimização e as métricas utilizadas; no Capítulo 5 são apresentados os resultados e as discussões sobre o que foi obtido; no Capítulo 6 contém a conclusão deste trabalho.

CAPÍTULO 2

2. Fundamentação Teórica

Neste capítulo serão explorados os temas em que o trabalho se baseia para sua proposição e implementação.

2.1 Tarifas de Energia

Com a expansão exponencial e ilimitada do uso da energia elétrica, as tarifas aplicadas a esse bem essencial foram sendo modificadas e se encontram hoje em um estado extremamente complexo com muitos fatores que podem interferir no balanço de conforto e economia na sociedade. A tarifa utilizada pelo consumidor hoje é composta por três outras tarifas distintas, a TE (Tarifa referente à energia elétrica consumida pelo usuário), a TUST (Tarifa referente ao uso do sistema de transmissão de energia) e a TUSD (Tarifa referente ao uso do sistema de distribuição de energia). Para a composição dessas tarifas, são considerados três custos distintos: Custo da Geração de Energia, Custo do Transporte de Energia e Encargos Setoriais e Tributos. O primeiro trata do valor pago pela distribuidora à geradora de energia elétrica, que atualmente é feito por meio de leilões. O segundo é dividido em duas etapas, o transporte de energia da geradora até a distribuidora (transmissão) e da distribuidora até o consumidor (distribuição). Por ser um monopólio natural desse transporte, o gerenciamento desses custos é controlado pela ANEEL. Por fim, o último custo trata dos tributos aplicados ao processo de comercialização de energia, entre eles temos: CDE, PROINFA, CFURH, EER, TFSEE, PEE e ONS. Além desses impostos, temos o tributo federal que varia mensalmente, PIS/COFINS; o tributo estadual, que varia em cada estado, ICMS, e é aplicado tanto à TE, como mercadoria, como da essência do tributo, quanto à TUST e TUSD, apesar de serem serviços; e o tributo municipal, COSIP, regulamentado pela câmara municipal de cada município.

Além desses fatores, temos as bandeiras tarifárias que fazem as tarifas serem acrescidas em períodos climáticos desfavoráveis, quando se faz necessário acionar as termelétricas por baixo nível dos reservatórios hídricos. Por fim, quanto ao custo da comercialização desse bem, também existem os diferentes valores de tarifa em função do horário, no caso da baixa tensão, a partir de 2018, clientes podem aderir a tarifa branca,

que dependendo da alocação das cargas durante o dia pode ser vantajoso ou desvantajoso ao consumidor. Essa medida visa reduzir os picos de energia que podem causar impactos na rede elétrica, devido à natureza das cargas, fazendo as variações entre picos de demanda indutiva e lacunas de demanda capacitiva sejam reduzidas. Com isso, são definidas tarifas maiores nos horários de pico, 18 às 21 horas, e em horários fora desse período há uma suavização da tarifa.

2.2 Conforto e Economia

Uma casa com muitos eletrodomésticos oferece conforto e praticidade aos moradores. Geladeira, Ar condicionado, televisões, máquinas de lavar roupas e louças, micro-ondas, forno elétrico, entre outros, são equipamentos que fazem parte da vida de muitas famílias, mas se por um lado eles proporcionam uma vida cheia de facilidades, por outro o uso reflete na conta de energia.

Além disso, há uma relação entre a maneira de usar esses equipamentos e seu consumo. Um dos maiores vilões do consumo domiciliar é o chuveiro elétrico, no entanto não há segredo: quanto maior a temperatura da água e o tempo de uso, maior será o consumo. De acordo com o gerente da área de eficiência energética da Copel, Gustavo Klinguelfus "quando a água do chuveiro está muito quente o ideal é reduzir a temperatura do equipamento em vez de abrir mais água. Chuveiros com controladores eletrônicos de potência são as melhores opções porque possuem regulagem contínua de temperatura e isso permite economizar". Outro eletrodoméstico que pode se tornar um problema na conta é a geladeira, sendo necessário, para melhorar a economia, reduzir a temperatura do termostato nos meses mais frios do ano


Considerando essas necessidades, enquanto as concessionárias vêm introduzindo essas variações na tarifa que consideram o horário de consumo e fatores climáticos, por exemplo, a conjuntura atual cria uma relação intrínseca e extremamente variável entre conforto e economia. Em muitas situações físicas e matemáticas é necessário encontrar um ponto de equilíbrio entre duas variáveis de crescimento inversamente proporcional, e isso pode e deve ser utilizado nesse exemplo, para que o consumidor se beneficie enquanto beneficia a concessionária, alocando suas cargas de uma melhor maneira.

2.3 Smart Home

As “casas inteligentes”, ou “Smart Homes”, é o nome dado a casas que seguem o conceito atual de integração entre os aparelhos eletrônicos, visando facilidades, como acessibilidade, segurança e conforto. As vantagens das Smart Homes falam por si só, como as citadas anteriormente, mas o contraponto da integração dessa inovação se dá pela necessidade de tecnologia avançada e custo elevado.

Sendo assim, uma casa completamente inteligente nos dias de hoje se resume a um luxo e não a uma necessidade, causando uma queda na procura por esse tipo de serviço. Em uma breve análise da popularidade desse assunto, através da ferramenta Google Trends, podemos ver que de 2004 ao ano presente, 2019, as pesquisas sobre esse assunto vêm caindo.

Figura 1: Número de pesquisas sobre Smart Home.



Fonte: <https://trends.google.com/trends/?geo=BR>

Com isso, além das facilidades faz-se necessária a integração da economia ao processo, bem como a popularização da tecnologia e o fomento às atividades que promovem esse avanço.

2.4 Controladores

Os controladores são equipamentos responsáveis pelo controle de processos de uma atividade, sendo empregado em diversas áreas, visto principalmente em indústrias. A evolução histórica desse equipamento se deu pela transição entre a utilização de controladores apenas pneumáticos para a inclusão e expansão dos controladores eletrônicos, marcados pela popularização dos transistores após a década de 1950 e posteriormente dos microprocessadores na década de 1980.

Esses aparelhos costumam ter uma malha de controle, em que são recebidas as informações, essas são processadas e ordens de controle são distribuídas. Durante o processamento, muitas lógicas de controle podem ser utilizadas, criando os parâmetros dos “tomadores de decisões”, exemplos dessas lógicas seriam: PID, lógica fuzzy, redes neurais e o próprio Algoritmo Genético.

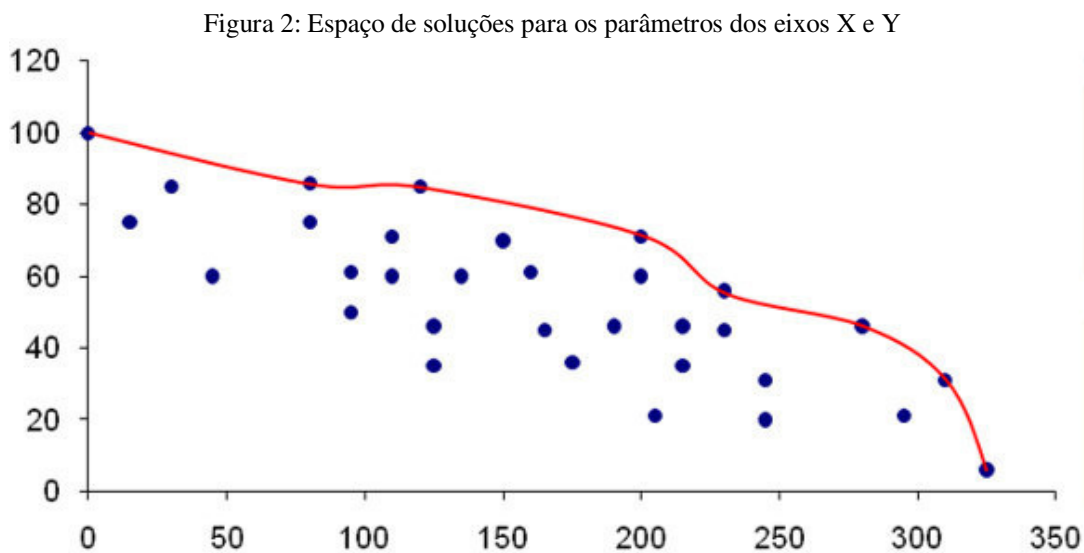
No âmbito residencial, a automação através de controladores de carga vem crescendo, como visto anteriormente. Para realizar essa automação, são necessários sensores, *drivers*, relés e até outros controladores, para realizar a captura de informações analógicas, para o processamento, e para a execução das ordens de controle. Como exemplo desses equipamentos, temos: acionamento de lâmpadas através de relés; monitorar o consumo de água através de sensores hidrômetros; sensores analógicos de temperatura e acionamento através de emissor infravermelho para um aparelho de ar condicionado. Para que seja feita a integração de toda essa malha de equipamentos é necessário o uso de um controlador de cargas.

CAPÍTULO 3

3. Metaheurística Multiobjetivo

A otimização multiobjetivo busca a obtenção de soluções chamadas não-dominadas, ou seja, que se sobressaem a outras soluções dentro da fronteira estabelecida entre os parâmetros da função aptidão; essa fronteira é denominada de Frente de Pareto e ir-se-á realizar uma maior explicação sobre esse indicador nos próximos capítulos.

A abordagem é feita, de maneira geral, em duas partes: Técnica e Apoio à tomada de decisão. Na fase Técnica são aplicadas estratégias buscando obter o espaço amostral de soluções mais diversas, contemplando toda a área estabelecida pelos parâmetros do problema multiobjetivo. Na fase de Apoio à tomada de decisão, as soluções são direcionadas ao tomador de decisões, que irá selecionar uma solução preferível ao problema proposto, usando os parâmetros da aptidão como critérios. Após a escolha das soluções, pode haver uma reciclagem destas para uma nova fase Técnica, caso o processo seja iterativo.



Fonte: Prata (2013)

Conforme Reeves e Beasley (1995), uma heurística é uma técnica que pesquisa boas soluções (ou seja, próximas do ótimo) com um custo computacional razoável, sem estar apta a garantir a otimalidade, ou a distância à otimalidade de uma dada solução.

De acordo com Blum e Roli (2003), uma meta-heurística é um conjunto de conceitos os quais podem ser usados para definir métodos heurísticos que podem ser aplicados a uma ampla gama de diferentes problemas.

Segundo Prata (2013), uma meta-heurística pode ser vista como um algoritmo genérico o qual pode ser aplicado em diferentes problemas de otimização com relativamente poucas modificações a serem realizadas na adaptação a um problema específico.

3.1 Algoritmo Genético

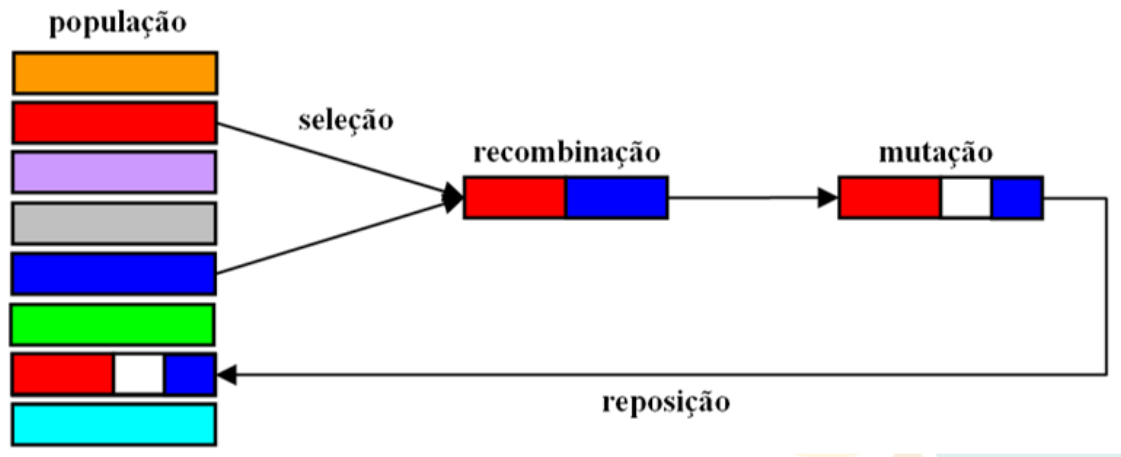
Algoritmo Genético (AG) é um método de otimização e rastreamento de soluções inspirado nos mecanismos de evolução populacional dos seres vivos, assim como outros algoritmos evolutivos que seguem técnicas relacionadas à hereditariedade, mutação, seleção natural e recombinação. Os algoritmos que seguem esse método foram introduzidos por John Holland (Holland, 1975) e popularizados por um de seus alunos, David Goldberg (Goldberg, 1989). Este método segue as premissas da seleção natural, em que o mais apto sobrevive, declarado em 1859 pelo naturalista e fisiologista inglês Charles Darwin em seu livro *A Origem das Espécies*. De acordo com Charles Darwin, “Quanto melhor um indivíduo se adaptar ao seu meio ambiente, maior será sua chance de sobreviver e gerar descendentes”.

Os AGs são muito eficientes em buscar soluções em problemas complexos, especialmente por não impor muitas das limitações, como encontradas em outros métodos, que acabam por mascarar possíveis soluções no grande espaço de soluções desses tipos de problemas. Essa complexidade vem do número de variáveis que podem ser apresentadas, tornando a convergência difícil. Os AGs têm convergência rápida para esse tipo de problema, por levar métodos simples de busca, em que a conjuntura que se assemelha à genética populacional, trata de espalhar a busca no espaço de soluções, deixando a critério do usuário o nível de refino da busca a partir da quantidade de iterações, em caso de método iterativo.

Inicialmente é gerada uma população de soluções, aleatórias ou pré-selecionadas. No decorrer do processo evolutivo, essa população é avaliada de acordo com uma função de aptidão: para cada indivíduo é dada uma nota, ou índice, refletindo sua habilidade de adaptação a determinado ambiente. Uma parte dessa população, chamados aqui de não-

dominados, que têm suas características não superadas por outras soluções, são selecionadas. As outras soluções, dominadas, que têm suas características superadas, anteriores à Frente de Pareto, são descartadas. Com a nova população não-dominada são feitas modificações adaptativas em suas características, como recombinação (crossover) e mutação. Após essas modificações, o processo de seleção é repetido com a nova população modificada, fazendo assim uma iteração:

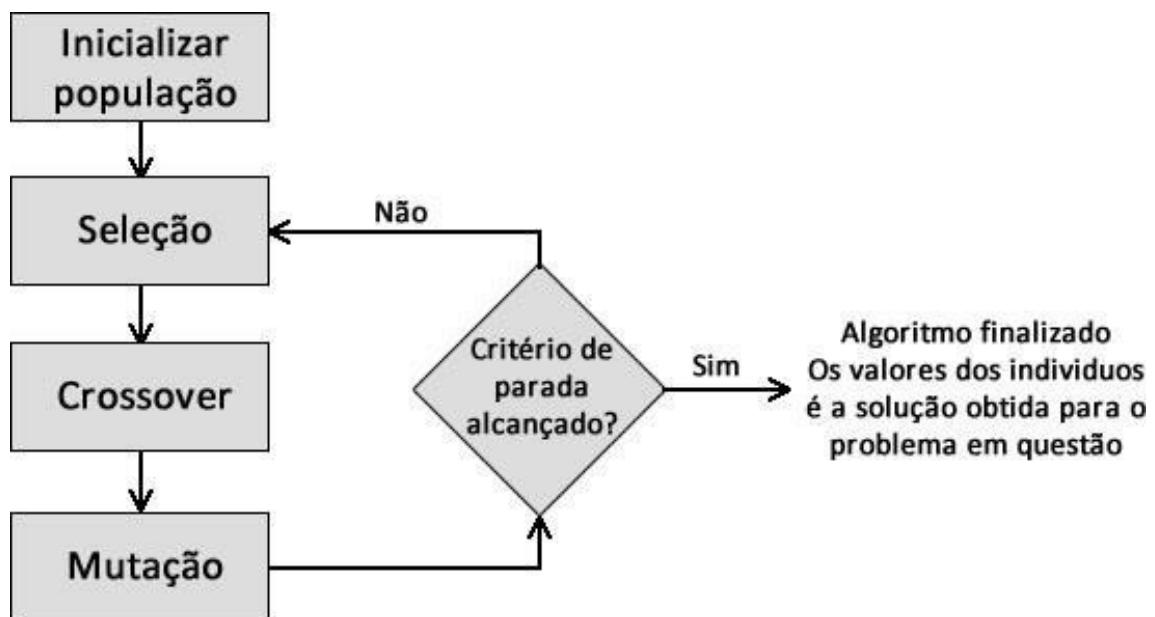
Figura 3: Fluxograma de um Algoritmo Genético de estado estacionário.



Fonte: Prata (2013)

Essas iterações são realizadas até que se atenda o critério de parada desejado:

Figura 4: Fluxograma do tomador de decisão.



Fonte: Prata (2013)

De acordo com Lacerda (2002) as técnicas de busca e otimização, geralmente, apresentam:

- Um espaço de busca, onde estão todas as possíveis soluções do problema;
- Uma função objetivo (algumas vezes chamada de função de aptidão na literatura de AGs), que é utilizada para avaliar as soluções produzidas, associando a cada uma delas uma nota.

Segundo Lacerda (2002) algumas vantagens dos AGs são:

- Funcionam tanto com parâmetros contínuos como discretos ou uma combinação deles.
- Realizam buscas simultâneas em várias regiões do espaço de busca, pois trabalham com uma população e não com um único ponto.
- Utilizam informações de custo ou recompensa e não derivadas ou outro conhecimento auxiliar.
- Não é necessário conhecimento matemático aprofundado do problema considerado.
- Otimizam um número grande de variáveis.
- Otimizam parâmetros de funções objetivos com superfícies complexas e complicadas, reduzindo a incidência de mínimos locais.
- Adaptam-se bem a computadores paralelos.
- Trabalham com uma codificação do conjunto de parâmetros e não com os próprios parâmetros.
- Fornecem uma lista de parâmetros ótimos e não uma simples solução.

- Trabalham com dados gerados experimentalmente e são tolerantes a ruídos e dados incompletos.
- São fáceis de serem implementados em computadores.
- São modulares e portáteis, no sentido que o mecanismo de evolução é separado da representação particular do problema considerado. Assim, eles podem ser transferidos de um problema para outro.
- São flexíveis para trabalhar com restrições arbitrárias e otimizar múltiplas funções com objetivos conflitantes.
- São também facilmente hibridizados com outras técnicas e heurísticas.

Com isso, um algoritmo genético típico é composto pelas seguintes etapas do pseudocódigo de um AG simples, mostrado no Quadro 1:

Quadro 1: Pseudocódigo de um AG simples.

INÍCIO

Seja $S(t)$ a população de cromossomos na geração t .

$t = 0$

inicializar $S(t)$

avaliar $S(t)$

enquanto o critério de parada não for satisfeito **faça**

$t = t + 1$

selecionar $S(t)$ a partir de $S(t-1)$

aplicar crossover sobre $S(t)$

aplicar mutação sobre $S(t)$

avaliar $S(t)$

fim enquanto

FIM

- **Inicialização**

Existem diversas maneiras para iniciar uma população de soluções. Caso a população não seja de tamanho ou variação suficiente, o espaço de soluções pode não ser totalmente representado por ela.

Para garantir a melhor representação do espaço de soluções, alguns métodos podem ser adotados: a população pode ser gerada de maneira uniformemente espaçada no espaço de busca; pode ser gerada uma parte aleatória para que a outra parte seja equidistante dessa com a inversão dos seus bits, garantidos que todos os bits tenham uma variante 1 e 0 na população, como na Tabela 1; e pode ser usada uma técnica denominada “seeding” em que a população inicial do AG contem indivíduos vindos das soluções de outros métodos de otimização utilizados anteriormente, evitando que o resultado do AG performe pior que os outros métodos.

Tabela 1: Geração equivalente invertida

1ª Metade gerada aleatoriamente	2ª Metade gerada aleatoriamente
1011010	0100101
0111011	1000100
0001101	1110010
1100110	0011001

Além disso, pode ser considerada a utilização de uma população inicial maior que as gerações seguintes, visando aumentar a área de busca coberta e que posteriormente será investigada.

- **Função Aptidão**

A Função Aptidão é o recurso que avalia a solução no processo de otimização, recolhendo as entradas e produzindo a qualidade da solução. A vantagem deste recurso está em não precisar ter uma função específica para o algoritmo, fazendo com que o problema possa ser de qualquer outro tema, apenas modificando a “caixa preta” da Função Aptidão.

Esse teste é realizado em todas as gerações e a partir dele podemos ter a visão no espaço multiobjetivo de quão próxima a solução está do ponto ótimo, tratando-a com os operadores de crossover e mutação as soluções que sejam aptas nessa análise. Em alguns casos da literatura, a função aptidão pode ser simplificada em partes do processo que exigem menos refino, como nas populações iniciais; isso pode reduzir o esforço computacional caso a Função Aptidão seja muito complexa.

- **Representação e Escolha dos Parâmetros**

Um AG utiliza populações de cromossomos. O cromossomo é a unidade que representa uma solução para o problema proposto que exige otimização. Em geral, pode-se dizer que o cromossomo é o vetor de uma solução, que tem alguma combinação dos parâmetros utilizados na Função Aptidão. O conjunto de cromossomos representa a população de soluções e todas as combinações possíveis para um cromossomo seria o espaço de busca.

Com isso, pode-se perceber que a escolha dos parâmetros do cromossomo, mensurados na Função Aptidão, definem as dimensões do problema, n parâmetros representam n dimensões. Além disso, existem outras características que podem influenciar na convergência da solução, entre elas: o tamanho da população, o número de gerações, a taxa de crossover e a taxa de mutação.

- **Seleção**

A Seleção se trata do processo de escolher os indivíduos da população que devem dar continuidade às iterações. Geralmente, é utilizado o método de seleção por “Roleta”, em que os indivíduos recebem probabilidades para serem escolhidos que seguem a sua nota de aptidão dada na Função Aptidão, quanto mais apto maior a chance de ser escolhido. Dessa forma a nova população contará, em sua maioria, com indivíduos mais aptos, mas também incluirá outros indivíduos menos aptos para manter a diversidade do conjunto de soluções; o que não acontece na seleção por “Truncamento”, em que os indivíduos mais aptos são escolhidos sem nenhum contraponto.

Além desses métodos, pode-se utilizar o método de seleção por “Torneio”, em que são selecionados diversos subconjuntos da população e os indivíduos mais aptos de cada subconjunto são escolhidos.

- **Crossover**

Como primeiro recurso para explorar melhor regiões desconhecidas do espaço de busca, o Crossover é aplicado a um par de cromossomos retirados da população, gerando dois cromossomos filhos. Cada cromossomo tem seu cerne dividido em duas partes, produzindo o que seriam duas cabeças e duas caudas do cromossomo. As partes são

mescladas entre os cromossomos, ou seja, a cauda de um vai para o outro. Existem várias maneiras de aplicar o Crossover: cruzamento com um ponto de corte, cruzamento com dois pontos de corte, cruzamento uniforme, cruzamentos híbridos, etc. O Crossover pode ser aplicado à uma probabilidade, para que o processo de recombinação seja feito de forma aleatória, a essa probabilidade dá-se o nome de Taxa de Crossover (essa taxa é estimada entre 60% e 90% da população, segundo a revisão bibliográfica). Com essa taxa aplicada, alguns indivíduos são preservados, mantendo algumas soluções anteriormente avaliadas como dominantes.

- **Mutação**

O operador Mutação é responsável por alterar completamente um gene de um determinado cromossomo. Essa medida também é tomada para que o código não convirja muito cedo por falta de espalhamento no espaço de busca.

Como esse operador destrói a informação que estava contida no cromossomo, é necessário que se use uma pequena Taxa de Mutação (normalmente entre 0,1% e 0,5%, segundo a revisão bibliográfica), para que a informação obtida anteriormente não seja comprometida de forma negativa.


- **Elitismo**

Após os tratamentos realizados na população, que foi selecionada e testada em sua aptidão, alguns cromossomos apresentam características valiosas para a convergência desejada. Essas características podem ser perdidas durante os processos de Crossover e Mutação a qual a população será submetida. Sendo assim, é interessante preservar o melhor ou os melhores cromossomos que fizeram parte da população. Essa estratégia é denominada Elitismo.

O Elitismo promove uma busca mais direcionada, preservando o melhor cromossomo da população entre as gerações e, da mesma forma, a busca na região do espaço em que ele se encontra.


Na literatura é possível encontrar comparações entre o melhor cromossomo e a média da aptidão na população, e o desempenho do AG com e sem Elitismo. De acordo com Lacerda (2002) essa comparação pode ser feita através das figuras a seguir:

Figura 5: Melhor valor e valor Médio da Função Aptidão em cada geração.



Fonte: Lacerda (2002)

Figura 6: Desempenho com AG sem Elitismo e com Elitismo.



Fonte: Urbano (2002)

- **Terminologia**

Como visto, na biologia, a teoria da seleção natural diz que o meio ambiente seleciona os indivíduos mais aptos para a sobrevivência. Com isso, apenas os mais aptos conseguem se reproduzir e passar as suas características genéticas às próximas gerações, em contraponto aos não aptos, que geralmente são eliminados antes da reprodução. Durante o processo de reprodução existem fenômenos genéticos, como crossover (recombinação), mutação e outros, que atuam por diferenciar o material genético desses indivíduos mais aptos. Essa variação permite a criação de novos seres aptos ao ambiente, que por sua vez passarão suas características para a prole.

Um AG é uma metáfora desses processos naturais, justificando a utilização de vários termos da biologia. Segundo Lacerda (2002) encontramos os seguintes termos na literatura:

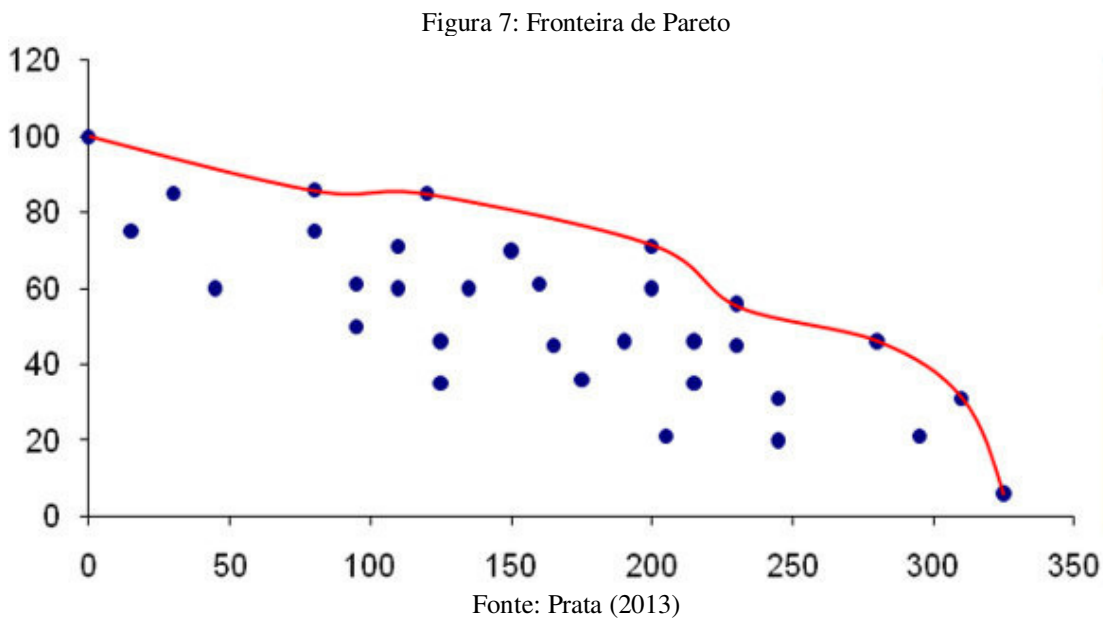
- Cromossomo e Genoma: Na biologia, genoma é o conjunto completo de genes de um organismo. Um genoma pode ter vários cromossomos. Nos AGs, os dois representam a estrutura de dados que codifica uma solução para um problema, ou seja, um cromossomo ou genoma representa um simples ponto no espaço de busca.
- Gene: Na biologia, é a unidade de hereditariedade que é transmitida pelo cromossomo e que controla as características do organismo. Nos AGs, é um parâmetro codificado no cromossomo, ou seja, um elemento do vetor que representa o cromossomo.
- Indivíduo: Um simples membro da população. Nos AGs, um indivíduo é formado pelo cromossomo e sua aptidão.
- Genótipo: Na biologia, representa a composição genética contida no Genoma. Nos AGs, representa a informação contida no cromossomo ou genoma.
- Fenótipo: Nos Algoritmos Genéticos, representa o objeto, estrutura ou organismo construído a partir das informações do genótipo. É o cromossomo decodificado. Por exemplo, considere que o cromossomo codifica parâmetros como as dimensões das vigas em um projeto de construção de um edifício, ou as conexões e pesos de uma Rede Neural. O fenótipo seria o edifício construído ou a Rede Neural.
- Alelo: Na biologia, representa uma das formas alternativas de um gene. Nos AGs, representa os valores que o gene pode assumir. Por exemplo, um gene que representa o parâmetro cor de um objeto poderia ter o alelo azul, preto, verde, etc.
- Epistasia: Interação entre genes do cromossomo, isto é, quando um valor de gene influencia o valor de outro gene. Problemas com alta Epistasia são de difíceis solução por AGs.

3.2 Pareto Envelope-based Selection Algorithm (PESA)

Foi visto anteriormente que os Algoritmos Evolucionários (EA) são eficazes na busca de soluções para problemas de MOO, ou seja, quando existe mais de uma função objetivo envolvida no critério para encontrar uma boa solução. Sendo assim, é necessário que haja uma técnica sendo utilizada para administrar as escolhas de soluções que tenham suas características diferentemente avaliadas nas funções objetivo.

Neste trabalho foi utilizado o método que se baseia em uma frente de Pareto para obter as soluções mais otimizadas. Normalmente, em uma situação de otimização multiobjetivo, os objetivos devem ser balanceados por serem de natureza conflitante, sendo necessário trabalhar com a relação de *trade-offs*, em que é preciso abdicar de uma característica em detrimento de outra, se o *trade-off* for positivo, esta pode ser uma boa solução.


Através dessa busca pela melhor troca entre os objetivos das soluções, é criado o conceito de dominância, onde a solução que apresenta uma proximidade maior do ponto ótimo é considerada dominante em relação a uma solução mais distante. Através desses pontos dominantes, traçada uma fronteira, como citado anteriormente, denominada fronteira de Pareto.



O PESA, apresentado em Corne et al. (2007), é uma técnica de seleção por região, no espaço de soluções, que utiliza a definição de hipercaixas (*hyperboxes*, *hypergrid*) para analisar a dominância das soluções e explorar esses locais. A densidade de uma hipercaixa

é dada pelo número de soluções não-dominadas nela contida. Na Figura 8 é ilustrado o conceito de hipercaixas considerando um problema de otimização envolvendo duas funções objetivo f_1 e f_2 . Neste caso tem-se uma hipercaixa com densidade igual a 1, duas com densidade igual a 2, uma com densidade igual a 3 e as demais com densidade nula (PRATA, 2011).

Figura 8: Hipercaixas no espaço de soluções.



Fonte: Prata (2011)

O algoritmo PESA-II Corne et al. (2001) introduz a utilização das regiões na seleção. Utilizando essa característica no lugar da seleção por indivíduos, existe uma variedade maior na cobertura das regiões próximas às soluções não-dominadas ao longo da Fronteira de Pareto.

Tabela 2: Comparação PESA e PESA-II

Algoritmo	Princípio	Vantagens	Desvantagens
PESA	Divide o espaço dos objetivos em hipercaixas.	(i) Melhor exploração no entorno da frente de Pareto; (ii) Mitiga a convergência prematura da população; (iii) Controle de diversidade e seleção operam por um mesmo mecanismo. (iv) Fácil implementação; (v) Performance eficiente.	(i) Dependência do parâmetro de formação dos hipercaixas.
PESA-II	Trabalha com hipercaixas, ao invés de trabalhar com soluções.	(i) Mesmas características do PESA; (ii) Maior probabilidade em explorar regiões pouco densas na frente de Pareto.	(i) Dependência do parâmetro de formação dos hipercaixas.

Fonte: Prata (2013).


3.3 Métricas

3.3.1 Hipervolume

Segundo Zitzler et al. (2007) o indicador de hipervolume é uma métrica para avaliar conjuntos de estimativas do conjunto Pareto-ótimo que possui a propriedade de Pareto conformidade, muitos indicadores de qualidade não possuem essa propriedade fundamental. Por conta disso, o indicador hipervolume tornou-se um consenso, quando se trata de avaliar o desempenho de um *Multiobjective Genetic Algorithm* (MOGA).

O hipervolume é uma métrica utilizada para analisar a proximidade das soluções geradas, que estão compondo a Fronteira de Pareto, do ponto considerado ótimo. Uma outra característica dessa métrica é que se pode analisar quanto ao espalhamento das soluções obtidas, visto que as posições das soluções definem o espaço entre elas e o ponto ótimo. No caso deste trabalho, tem-se dois objetivos a serem otimizados, portanto se trata de uma área, como na figura a seguir:

Figura 9: Ilustração do hipervolume.



Fonte: Diógenes (2017)

3.3.2 Tempo

Quando se trabalha com um método iterativo de programação, o esforço computacional de realizar várias iterações até o ponto desejado pode ser demasiado. Foi adicionado um contador de tempo para a operação do código, a fim de avaliar a eficiência da solução quanto ao esforço computacional exigido.

CAPÍTULO 4

4. Estrutura do Código

Neste capítulo serão abordadas as estruturas do sistema utilizado neste trabalho.

4.1 Arquitetura.

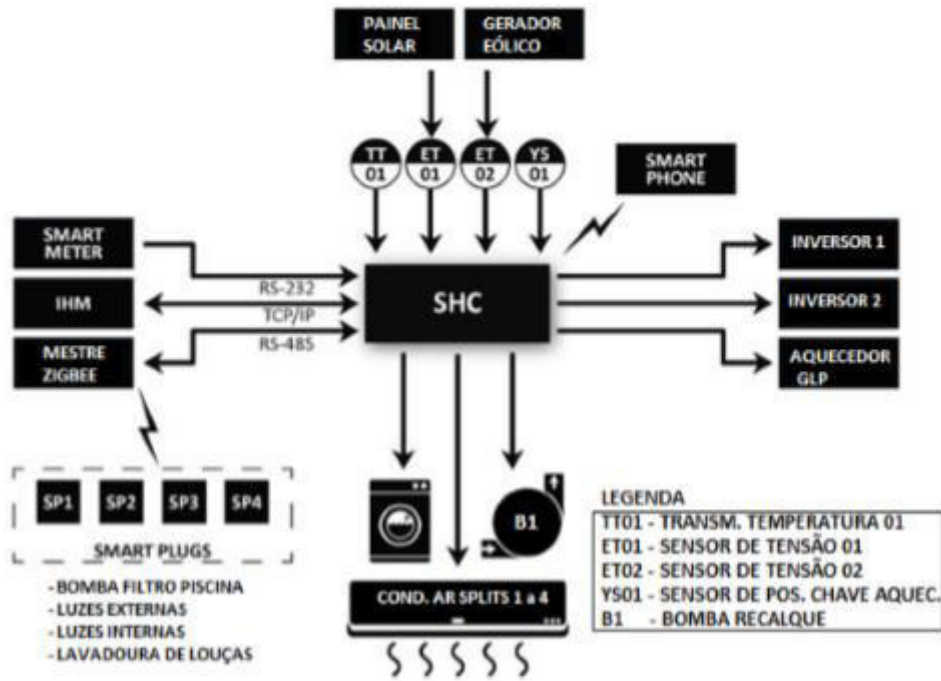
Para a realização das simulações, foi adotada uma arquitetura específica para o *Smart Home Controller* (SHC). Além disso, para incrementar a simulação, as cargas foram diferenciadas entre Cargas controláveis (*Controllable loads – CL*) e Cargas detectáveis (*Detectable loads – DL*).

Cargas controláveis são as cargas que podem ser desligadas por um período de tempo com ou sem implicações na qualidade de serviço. Estas são diretamente conectadas ao SHC que irá exercer o papel de controlador. Exemplos de cargas CL são: ar condicionado, aquecedor e máquina de lavar roupas.

Cargas detectáveis são cargas não controláveis que podem ter seus valores estimados pela diferença entre o Medidor inteligente (*Smart Meter – SM*) e de todas as outras CL. Exemplos de cargas DL: iluminação, geladeira, torradeira e equipamentos televisores.

A arquitetura do sistema do SHC utilizado neste trabalho é ilustrada na Figura 10. De acordo com o criador do sistema, o SHC gerência todas as cargas e funcionamento dos sistemas de fontes renováveis (eólica e solar). O SHC define o funcionamento das cargas a partir da leitura das informações obtidas por meio dos dispositivos de medição instalados na residência e do resultado da execução da programação determinada pela função objetivo. O SHC realiza as seguintes atividades: gerenciamento do funcionamento dos microgeradores eólico e solar, a partir da leitura das tensões das baterias (ET01 e ET02) com acionamento dos inversores de cada sistema; leitura da temperatura da água quente (TT01); status da posição da chave de seleção do aquecedor (GLP/termo sifão); controle das cargas e comunicação com o SM, SP (mestre Zigbee), IHM e *smart phone*.

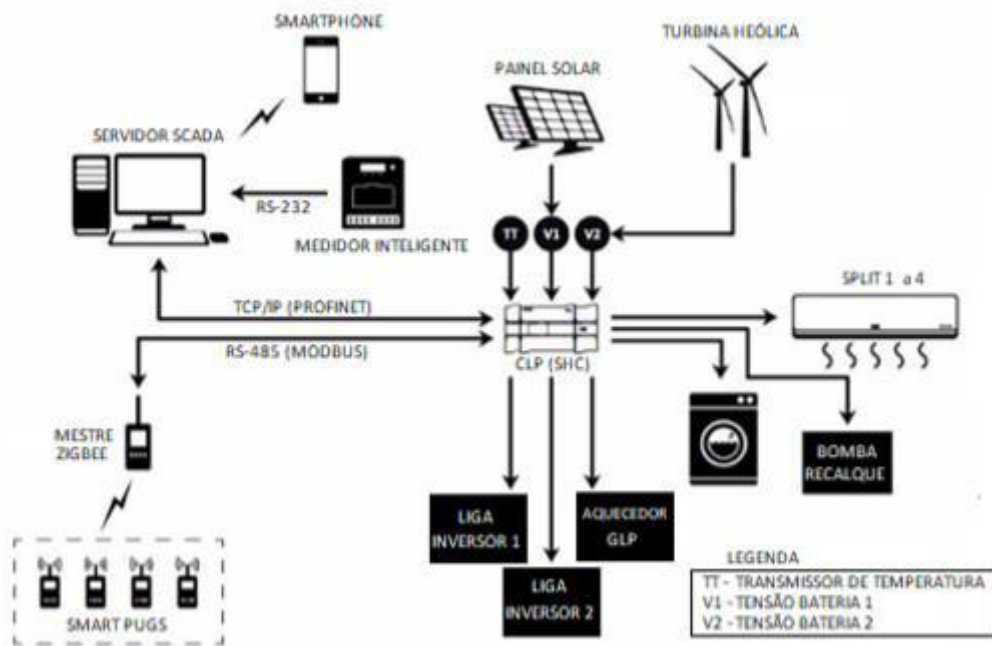
Figura 10: Arquitetura do sistema SHC.



Fonte: Urbano (2018)

Na Figura 11 é apresentada a arquitetura do protótipo da plataforma de testes para validação da solução. O sistema é uma plataforma baseada em equipamentos industriais (CLP, Sensores, contadores, etc.) associados a SP desenvolvidos em laboratório.

Figura 11: Arquitetura da plataforma de testes.



Fonte: Urbano (2018)

De acordo com Urbano (2018), o SHC realiza as seguintes tarefas:

- Comunica-se com as tomadas inteligentes (SP) através do coordenador de rede (ZIGBEE manager), para ler o consumo de energia e controlar o status de funcionamento do equipamento que está ligado em cada SP, através de uma comunicação RS485, utilizando o protocolo MODBUS;
- Lê os valores de demanda e consumo de energia do medidor de energia inteligente (SM) através de uma comunicação RS232, utilizando o protocolo ABNT (Associação Brasileira de Normas Técnicas);
- Recebe as definições de funcionamento das cargas a partir da Interface Humano-Maquina (IHM) através de uma comunicação TCP/IP Ethernet;
- Controla diretamente as cargas controláveis através do agendamento do horário de funcionamento de cada equipamento;
- Define o modo de funcionamento dos equipamentos de micro geração e aquecimento.

4.2 Lógica de Funcionamento do Código

Neste tópico será mostrada a lógica de funcionamento do MOO baseado em algoritmo genético multiobjetivo (MOGA), bem como as funções objetivo e o cenário de cargas escolhido.

4.2.1 Funções Objetivo

As funções objetivo foram modeladas para os indicadores de Custo e Conforto. Na Tabela 3, estão os parâmetros considerados nas funções objetivo:

Tabela 3: Parâmetros das Funções Objetivo.

Símbolo	Descrição
C	Número de cargas controláveis
\bar{P}_c	Potência média da carga c
\hat{P}_c	Potência de pico da carga c
T_A	Tempo de amostragem
T_a	Tarifa diária
u_{ci}	i -ésima variável booleana de decisão da carga c
I_{Ic}	Amostra referente ao tempo mínimo de início da carga c
I_{Fc}	Amostra referente ao tempo máximo de encerramento da carga c
N_c	Duração, em amostras, do acionamento da carga c
N	Número de amostras de tempo
I	Horário de início do período de planejamento das cargas
F	Horário de encerramento do período de planejamento das cargas
Dem_{max}	Demanda máxima contratada (teórica)
R_{Nc}	Nível de relevância da carga c
I_{Mc}	Amostra referente ao melhor horário de acionamento de uma carga c
α	Parâmetro para ponderar as funções objetivo. Varia de 0, conforto máximo, a 1, economia máxima.
D_{max}	Distância máxima, em amostras, entre o melhor horário de uma carga, I_{Mc} , e seus limites de acionamento, I_{Ic} e I_{Fc} .
M_c	Número de vezes que a carga c é acionada no dia.

Fonte: Urbano (2018)

4.2.1.1 Custo com Energia Elétrica

Como função de análise da maximização da economia de energia elétrica, considerando a conjuntura de cargas escolhida pelo usuário, este trabalho utiliza uma modelagem semelhante a apresentada em Di Giorgio e Pimpinella (2012), mas com tempos de amostragens de um minuto, em que é considerado um sistema discreto baseado nos seguintes parâmetros:

- Tarifa diária;
- Demanda máxima contratada;
- Potências média e de pico de cada carga;
- Horários mínimos e máximos de acionamento das cargas, definidos pelo usuário.

Dado o modelo de tempo discreto com taxa de amostragem T_A , a distribuição das horas de um dia é dada por N amostras. Dado que uma residência possui C cargas a serem

controladas pelo SHC, a modelagem matemática do custo com energia elétrica destas cargas é apresentada na equação a seguir:

$$cost(c) = \sum_{c=1}^C \sum_{i=I_{Fc}}^{I_{Fc}-N_c i+(N_c-1)} \sum_{n=i} \bar{P}_c[n-i] T_A T a[n] \quad (1)$$

em que,

P: Potência média de cada carga, utilizada para calcular o custo financeiro;

Ta: Valor de tarifa aplicado;

T_A : Tempo de amostragem;

n: 0, 1, . . . , N -1.

Na equação a seguir é apresentada a restrição que garante que o acionamento das cargas não irá exceder o valor de demanda contratado.

$$\sum_{c \in C_k} \sum_{i=k-(N_c-1)}^{k-(k-I_{Fc}+N_c)^+} \hat{P}_c[k-i] \leq Dem_{max} \quad (2)$$

em que,

$k = I, I + 1, \dots, F - 1$

P_c: Potência de pico da carga c;

I, F: Horários de acionamento e desligamento do período de planejamento da carga.

Para a utilização da função modelo para custo, é necessário um valor de referência, ou seja, um valor médio para a configuração das cargas escolhidas pelo usuário:

$$custo_{s-shc} = \sum_{c=1}^C \sum_{n=I_{Mc}}^{I_{Mc}+(N_c-1)} \bar{P}_c[n-I_{Mc}] T_A T a[n] \quad (3)$$

Dessa forma, se faz necessária uma função de relação entre o valor otimizado de custo e o valor de referência considerado pelo usuário, essa função será referenciada de agora em diante como f_1 :

$$f_1 = \sum_{c=1}^C \left[\sum_{n=I_{Mc}}^{I_{Mc}+(N_c-1)} \bar{P}_c[n-I_{Mc}]T_A T_a[n] - \sum_{i=I_{Ic}}^{I_{Fc}-N_c} \sum_{n=i}^{i+(N_c-1)} \bar{P}_c[n-i]T_A T_a[n] \right] \quad (4)$$

4.2.1.2 Conforto

Neste caso, o conforto é medido pelo nível de proximidade com a conjuntura de cargas colocada pelo usuário. Sendo assim, o usuário seleciona os horários de sua preferência para as cargas, e quão mais próxima a configuração resultante da otimização for da configuração escolhida pelo usuário, maior será o conforto.

Novamente, como o problema está sendo tratado com modelagem de tempo discreto, o conforto será a diferença entre a configuração de horário escolhida pelo usuário e a configuração de acionamento definida pela otimização.

Sendo assim, o conforto é definido como:

$$\text{comfort}_c(i) = D_{\max} - R_{Nc}|i - I_{Mc}| \quad (5)$$

em que,

$$D_{\max} = \max(|I_{Ic} - I_{Mc}|, |I_{Fc} - I_{Mc}|) \quad (6)$$

Na primeira equação, é definida a diferença entre a hora resultante do SHC e a hora escolhida pelo usuário ($|i - I_{Mc}|$) para uma carga c . Em seguida, essa distância é ponderada pelo nível de relevância daquela carga, ajustando o valor para a subtração mais apropriada com o D_{\max} que seria um valor de referência. Na equação seguinte é definido o valor de referência como sendo a maior distância entre o horário selecionado pelo usuário (I_{Mc}) e os limites do acionamento (I_{Ic}, I_{Fc}) de uma carga c .

Sendo assim, considere uma carga c como sendo de máximo nível de relevância ($R_{Nc} = 1$). Quando $i = I_{Mc}$ significa que a carga está o mais próximo da escolha do usuário, portanto conforto máximo. Quando $i = I_{Ic}$ significa que o conforto será mínimo, visto que está no ponto mais distante do que foi solicitado pelo usuário.

Então, o conforto é definido como:

$$f_{2,1} = \sum_{c=1}^C \sum_{i=I_{Ic}}^{I_{Fc}-N_c} D_{max} - R_{Nc} |i - I_{Mc}|$$

Em acionamentos multiciclos, cada carga irá possuir mais de um horário escolhido pelo usuário (I_{Mc1}, I_{Mc2}) e portanto, mais de um valor de referência (D_{max1}, D_{max2}). Dessa forma, D_{max} e f_2 passam a ser definidos como:

$$D_{max_k} = \max(|I_{Ic} - I_{Mc_k}|, |I_{Fc} - I_{Mc_k}|)$$

$$f_2 = \sum_{c=1}^C \sum_{i=I_{Ic}}^{I_{Fc}-N_c} \sum_{k=1}^M (D_{max_k} - R_{Nc} |i - I_{Mc_k}|) \frac{1}{M_c}$$

em que,

M_c : Número de vezes que a carga c é acionada no dia.

4.2.2 Cenário

Para o estudo foi selecionado um cenário de cargas, em que foram utilizadas 11 cargas elétricas, com valores de potência, duração e horário de acionamento de acordo com a Figura 12. A carga referente ao Ferro de engomar não foi considerada controlável por não ser utilizada diariamente e ter especificações no ligamento (tomada).

A configuração assumida por essas cargas é lida a partir de um arquivo criado a partir da Figura 12. Cada gene representa uma dessas cargas, sendo o cromossomo formado por esses genes e, portanto, esse número de genes representa a quantidade de cargas, que nesse caso é 10, visto que o Ferro de engomar não está incluso.

Figura 12: Duração e horário de acionamento das cargas.

ID	(CL) Nome	Fases	Δt (min)	\bar{P} (kW)	\hat{P} (kW)	Hora ideal	Faixa de horário		R_N
							Das	As	
1	Bomba recalque	1	20	2	3	08h00	07h00	17h00	0,1
2	Bomba filtro	1	120	0,75	1,5	08h00	07h00	17h00	0,1
3	Ferro de engomar	1	120	1	1,2	16h00	14h00	17h00	0,3
4	Máquina de lavar roupa	8	10; 10; 4; 6; 2; 2; 2; 7	0,13; 0,51; 0,3; 0,26; 0,15; 0,15; 0,15; 0,22	0,7; 0,51; 0,3; 0,26; 0,15; 0,15; 0,15; 0,3	8h00	7h00	17h00	0,5
5	Iluminação externa	1	270	0,3	0,3	18h00	17h00	23h55h	0,3
6	Iluminação interna	1	270	0,15	0,3	18h00	17h00	23h00	0,7
7	Ar condicionado gabinete	14	10; 5;...;5	1,3; 1,3; ...; 1,3	1,7; 1,3; ...; 1,3	20h00	17h00	23h55h	1,0
8	Ar condicionado casal	7	30; 20; 5; 5; 5; 5; 5	2; 2; 2; 2, 2, 2	2,1; 2,1; 2,1; 2,1; 2, 2, 2	20h00	17h00	23h55h	1,0
9	Ar condicionado F1	1	240	1,1	1,2	20h00	17h00	23h55h	1,0
10	Ar condicionado F2	7	10; 10; 5; 5; 5; 5; 5	0,9; 0,9; 0,9; 0,9; 0,9; 0,9; 0,9	1,1; 1,1; 1,1; 1,1; 1,1; 1,1; 1,1	20h00	17h00	23h55h	1,0
11	Máquina de lavar louça	5	5; 10; 15; 5; 10	0,033; 1,76; 0,033; 1,76; 0,033	0,033; 1,76; 0,033; 1,76; 0,033	21h00	18h00	22h00	0,3

Fonte: Urbano (2018)

No quadro a seguir é mostrado o arquivo *input_acio.txt*, que é usado como referência para a criação das cargas, um cromossomo terá 10 genes, o primeiro gene é representado por “*Booster pumps*”, o segundo por “*Filter pumps*”, e assim por diante.

Quadro 2: Arquivo com as características.

```

STATUS=0
DATE=16/02/2017
TIME=16:10:37
ALFA=0
TARIFF=2
NAMES=Booster pumps;Filter pumps;Washing machine;Outdoor lightning;Indoor
lightning;Office's air conditioner;Couple's air conditioner;F1's air conditioner;F2's air
conditioner;Dishwasher
N_PHASES=1;1;8;1;1;14;7;1;7;5
MIN_TIME=7:00;7:00;7:00;17:00;17:00;15:00;17:00;17:00;17:00;18:00
MAX_TIME=17:00;17:00;17:00;24:00;23:00;24:00;24:00;24:00;24:00;22:00
BEST_TIME=8:00;16:00;8:00;8:00;18:00;18:00;16:00;20:00;20:00;20:00;21:00
COMFORT_LEVEL=0.1;0.1;0.5;0.3;0.7;1;1;1;0.3
PHASE_DURATION=20;120;10;10;5;10;5;5;5;10;270;270;10;5;5;5;5;5;5;5;5;5;5;30;20;
5;5;5;5;5;240;10;10;5;5;5;5;5;10;15;5;10
AVG_POWER=2;0.75;0.13;0.51;0.3;0.26;0.15;0.15;0.15;0.22;0.3;0.15;1.3;1.3;1.3;1.3;1.3;1.3;
1.3;1.3;1.3;1.3;1.3;1.3;1.3;1.3;2.2;2.2;2.2;2.2;1.1;0.9;0.9;0.9;0.9;0.9;0.9;0.9;0.033;1.76;0.033;1.7
6;0.033
PEAK_POWER=3;1.2;0.7;0.51;0.3;0.26;0.15;0.15;0.15;0.3;0.3;0.3;1.7;1.3;1.3;1.3;1.3;1.3;1.3;
1.3;1.3;1.3;1.3;1.3;1.3;2.1;2.1;2.1;2.1;2.2;2.2;1.2;1.1;1.1;1.1;1.1;1.1;1.1;1.1;1.1;0.033;1.76;0.033;
1.76;0.033
    
```

Fonte: Urbano (2018)

4.2.3 Cenário PESA II

No cenário de cargas comentado anteriormente, foi aplicado o algoritmo PESA II para as funções objetivo destacadas neste trabalho. No Quadro 3 é mostrado o pseudocódigo utilizado nesse cenário de cargas e que ao fim das N_g gerações será obtida uma frente de Pareto composta pela população externa (EP). Além disso, são adicionados à população inicial os dois melhores indivíduos resultantes de uma otimização anterior.

Quadro 3: Pseudocódigo do PESA II.

<p>INÍCIO</p> <ol style="list-style-type: none">1. Gera a população com N_i-2 candidatos aleatórios;2. Insere na população os dois melhores indivíduos da PL inteira para cada situação monoobjetivo (economia, custo);3. Define quantos filhos existirão a cada iteração (N_f) e quanto indivíduos serão mutados por geração (N_i-N_f);4. Enquanto o critério de parada não for alcançado (N_g gerações) repita:<ol style="list-style-type: none">a. Avalia a aptidão da população;b. Determina a dominância dos indivíduos da população;c. Seleciona os indivíduos não dominados e os adiciona à EP;d. Determina a dominância dos indivíduos da EP e remove os dominados;e. Cria <i>hypergrid</i> de espalhamento das soluções da EP;f. Caso o tamanho de EP seja maior que o definido inicialmente (n_{EP}), remove indivíduos baseado no espalhamento do <i>hypergrid</i>;f. Gera filhos a partir da reprodução de indivíduos do EP;g. Aplica mutação em (N_i-filhos) elementos da EP;h. Monta a população para a próxima geração a partir da união dos filhos e os indivíduos mutados. <p>OK FIM</p>
--

Fonte: Próprio Autor

4.2.4 Aplicação da Métrica

Como citado anteriormente, os métodos utilizados para qualificar as soluções do estudo são de *hipervolume* e *tempo*. Para a implementação desses indicadores, foram utilizadas as funções *tic toc* e *hipervolume(x,y)* do Matlab. Em que o ponto de referência adotado para cálculo da área foi escolhido como (0, 0), sendo assim, quão maior for o *hipervolume*, mais próxima essa solução estará do ponto ótimo.

Foram criados dois vetores para armazenar esses indicadores após a realização de cada repetição do código completo, *tempoea* e *hiperea*. A cada ciclo da estrutura *for* que repete o código, o valor aferido no *toc* é armazenado em uma posição do vetor *tempoea*; assim como a cada ciclo o valor da função *hipervolume* é armazenado em uma posição do vetor *hiperea*. A função *hipervolume* tem como entradas o ponto de referência,

anteriormente mostrado, e o vetor de soluções que são plotadas no gráfico. No Quadro 4 está a estrutura para medição desses indicadores.

Quadro 4: Estrutura de Medição.

INÍCIO

tempoea é um vetor de N entradas

hiperea é um vetor de N entradas

para *o* variando de 1 a N **faça**

início contagem tempo

inicializar S(t)

avaliar S(t)

enquanto o critério de parada não for satisfeito **faça**

t = t+ 1

selecionar S(t) a partir de S(t-1)

aplicar crossover sobre S(t)

aplicar mutação sobre S(t)

avaliar S(t)

fim enquanto

ref = (0, 0)

hiperea(o) = *hipervolume*[ref, S(t)]

tempoea(o) = fim contagem tempo

fim para

colhe dados de tempo

colhe dados de hipervolume

FIM

Fonte: Próprio Autor

CAPÍTULO 5

5. Resultados

Nesta parte serão discutidos os resultados obtidos através a execução do código e das comparações feitas em tabelas e gráficos. Esta será dividida em duas análises: análise por acréscimo de gerações e análise por acréscimo de repetições.

Para cada análise, foi gerada uma tabela, Tabela 4, com todas as informações escolhidas, essa tabela apresenta valores de tempo máximo (Tmax), tempo mínimo (Tmin) e tempo médio (Tmed) de execução do código, medidos em segundos; hipervolume máximo (Hmax), hipervolume mínimo (Hmin) e hipervolume médio (Hmed) da solução, medidos em área sobre o gráfico. Esses indicadores estão distribuídos entre as opções de 1, 5, 10, 20, 40 e 80 gerações presentes no código; e para cada um desses cenários o código foi repetido 10, 30, 70, 150 e 300 vezes.

Tabela 4: Tabela completa de resultados.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
10	1	0.95	0.34	0.65	0.4729	0.4602	0.4660
	5	4.89	2.14	3.19	0.4932	0.4801	0.4864
	10	11.24	5.06	6.85	0.4932	0.4757	0.4894
	20	17.22	12.63	14.81	0.4948	0.4896	0.4925
	40	29.11	22.49	26.25	0.4958	0.4912	0.4938
	80	70.92	57.08	65.73	0.4969	0.4943	0.4953
30	1	1.22	0.21	0.64	0.4783	0.4602	0.4669
	5	4.74	1.99	3.24	0.4938	0.4653	0.4849
	10	9.63	4.85	6.98	0.4943	0.4779	0.4883
	20	23.78	12.11	16.12	0.4952	0.4854	0.4912
	40	35.08	25.60	29.52	0.4970	0.4907	0.4940
	80	77.42	55.55	64.02	0.4979	0.4924	0.4951
70	1	1.93	0.24	0.70	0.4786	0.4602	0.4668
	5	6.02	2.06	3.68	0.4925	0.4634	0.4830
	10	14.10	5.15	7.72	0.4954	0.4776	0.4885
	20	23.32	9.89	15.61	0.4954	0.4862	0.4917
	40	81.78	22.36	48.29	0.4985	0.4896	0.4935
	80	148.23	68.20	116.29	0.5004	0.4913	0.4953
150	1	5.82	0.41	1.28	0.4798	0.4602	0.4658
	5	6.96	1.70	3.34	0.4931	0.4625	0.4839
	10	25.50	4.38	8.90	0.4949	0.4723	0.4885
	20	21.93	9.28	13.64	0.4976	0.4817	0.4920
	40	79.94	22.42	42.06	0.4963	0.4903	0.4937
	80	139.26	49.20	79.63	0.4988	0.4918	0.4952

300	1	2.21	0.19	0.60	0.4813	0.4602	0.4660
	5	12.03	2.43	6.35	0.4934	0.4647	0.4831
	10	22.88	7.27	12.38	0.4950	0.4679	0.4882
	20	38.10	9.43	19.91	0.4983	0.4836	0.4919
	40	32.53	20.54	25.54	0.4980	0.4899	0.4938
	80	136.62	47.22	60.58	0.5001	0.4912	0.4952

É importante destacar que para as comparações de tempo, o fator hardware é extremamente importante, podendo ser um causador das anomalias que poderão aparecer. Os códigos foram executados em um computador de processador Intel® Pentium® CPU G4560 @ 3.50 GHz e 8,00 GB de memória RAM instalada.

5.1 Análise por Acréscimo de Gerações

Para visualizar de maneira completa o que se pode extrair das soluções, são apresentados gráficos das evoluções por acréscimo de gerações de todas as opções de repetição.


A expectativa para essa parte da análise é verificar se existe uma evolução nas soluções pelo acréscimo de gerações no processo evolucionário do código, bem como a partir de qual ponto o código passa a ser mais confiável. Além disso, observar o impacto dessa alteração no tempo de execução do código.

- 10 Repetições:

Tabela 5: Resultados para 10 repetições.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
10	1	0.95	0.34	0.65	0.4729	0.4602	0.4660
	5	4.89	2.14	3.19	0.4932	0.4801	0.4864
	10	11.24	5.06	6.85	0.4932	0.4757	0.4894
	20	17.22	12.63	14.81	0.4948	0.4896	0.4925
	40	29.11	22.49	26.25	0.4958	0.4912	0.4938
	80	70.92	57.08	65.73	0.4969	0.4943	0.4953


Gráfico 1: Código 10x – Gerações x Tempo.



Fonte: Próprio Autor

Como esperado, existe um acréscimo de tempo com o aumento da quantidade de gerações, e esse aumento vai se tornando cada vez mais inclinado, principalmente após as 40 gerações. Além disso, é possível ver nesse momento que não há tanta variação nesses valores, apesar de depender diretamente do desempenho do hardware responsável pelo processo.

Gráfico 2: Código 10x Geração x Hipervolume.



Fonte: Próprio Autor

Para o hipervolume existe uma incongruência presente no código com 10 gerações, isso mostra a importância dos indicadores de tempo máximo e mínimo, que


percebem apesar da aparente normalidade no tempo médio. Essa incongruência mostra que em apenas 10 gerações pode haver um resultado não desejado, com hipervolume inferior, fato que pode ser facilmente solucionado aumentando o número de gerações, é possível ver que em 80 gerações existe quase uma constância seguida de uma baixa variação entre indicadores.

- 30 Repetições:

Tabela 6: Resultados para 30 repetições.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
30	1	1.22	0.21	0.64	0.4783	0.4602	0.4669
	5	4.74	1.99	3.24	0.4938	0.4653	0.4849
	10	9.63	4.85	6.98	0.4943	0.4779	0.4883
	20	23.78	12.11	16.12	0.4952	0.4854	0.4912
	40	35.08	25.60	29.52	0.4970	0.4907	0.4940
	80	77.42	55.55	64.02	0.4979	0.4924	0.4951


Gráfico 3: Código 30x Geração x Tempo.



Fonte: Próprio Autor

O formato para a evolução do tempo se repete.

Gráfico 4: Código 30x Geração x Hipervolume.



Fonte: Próprio Autor


Novamente o Tmin percebe uma incongruência nos primeiros cenários de gerações, mostrando mais uma vez insuficiência de estabilidade. É perceptível, pela suavidade da curva, que o espaçamento vai persistindo nos primeiros casos.

- 70 Repetições:

Tabela 7: Resultados para 70 repetições.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
70	1	1.93	0.24	0.70	0.4786	0.4602	0.4668
	5	6.02	2.06	3.68	0.4925	0.4634	0.4830
	10	14.10	5.15	7.72	0.4954	0.4776	0.4885
	20	23.32	9.89	15.61	0.4954	0.4862	0.4917
	40	81.78	22.36	48.29	0.4985	0.4896	0.4935
	80	148.23	68.20	116.29	0.5004	0.4913	0.4953

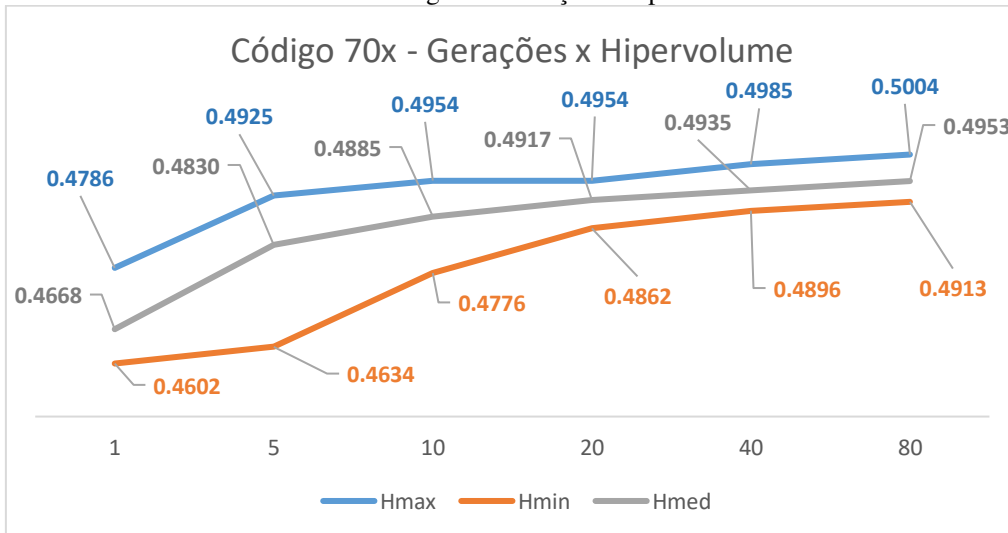
Gráfico 5: Código 70x Geração x Tempo.



Fonte: Próprio Autor

O formato persiste, mas há um aumento do espaçamento entre os cenários de 20 e 80 gerações em relação às repetições anteriores, podendo mostrar uma imprecisão na tentativa de ponderar o tempo pelo hipervolume, pois o tempo pode ter um “range” grande de resultados.

Gráfico 6: Código 70x Geração x Hipervolume.



Fonte: Próprio Autor

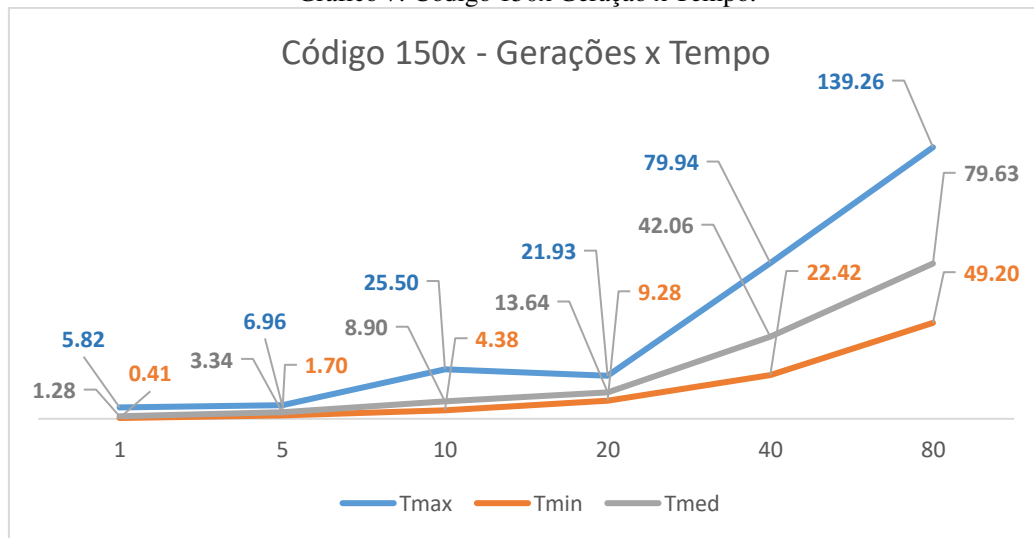
O formato é mantido e vem sendo consolidada a imprecisão nos primeiros cenários de geração. Além disso, pode ser observado o ponto de estrangulamento do Tmax e Tmin nas 20 gerações, mostrando involução da melhor resposta entre as 10 e as 20 gerações, apesar da média das 20 gerações se manter melhor.

- 150 Repetições:

Tabela 8: Resultados para 150 repetições.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
150	1	5.82	0.41	1.28	0.4798	0.4602	0.4658
	5	6.96	1.70	3.34	0.4931	0.4625	0.4839
	10	25.50	4.38	8.90	0.4949	0.4723	0.4885
	20	21.93	9.28	13.64	0.4976	0.4817	0.4920
	40	79.94	22.42	42.06	0.4963	0.4903	0.4937
	80	139.26	49.20	79.63	0.4988	0.4918	0.4952


Gráfico 7: Código 150x Geração x Tempo.



Fonte: Próprio Autor

O formato e a característica de espaçamento vistos no último cenário de repetições foi mantido. No entanto, houve uma anomalia entre os Tmax das 10 e 20 gerações, mostrando novamente uma imprecisão, mas dessa vez em escalas menores. Ademais, os valores médios seguem o padrão, mostrando o tipo de evolução real, na maioria dos casos.

Gráfico 8: Código 150x Geração x Hipervolume.



Fonte: Próprio Autor


O formato das 70 repetições é mantido, mas o grande espaçamento do indicador Tmin e o estreitamento pontual do Tmax evoluem das 20 para as 40 gerações.

- 300 Repetições:

Tabela 9: Resultados para 300 repetições.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
300	1	2.21	0.19	0.60	0.4813	0.4602	0.4660
	5	12.03	2.43	6.35	0.4934	0.4647	0.4831
	10	22.88	7.27	12.38	0.4950	0.4679	0.4882
	20	38.10	9.43	19.91	0.4983	0.4836	0.4919
	40	32.53	20.54	25.54	0.4980	0.4899	0.4938
	80	136.62	47.22	60.58	0.5001	0.4912	0.4952


Gráfico 9: Código 300x Geração x Tempo.



Fonte: Próprio Autor

O formato se manteve em todos os cenários. Neste último, é visto que a anomalia presente no Tmax do cenário de repetições anterior se manteve, no entanto, ela evoluiu das 20 para as 40 gerações. Sendo assim, podemos considerar o acréscimo de gerações um agravante quase exponencial do tempo, mas de difícil correlação precisa caso o número de gerações seja próximo o suficiente para sofrer essas anomalias.

Gráfico 10: Código 300x Geração x Hipervolume.



Fonte: Próprio Autor

O cenário anterior praticamente se repete, com acréscimo de alguns ruídos entre os pontos da curva. Observando este e os outros cenários, é fácil concluir que a constância é atingida apenas nas 80 gerações, bem como o espaçamento controlado e a linearidade de crescimento.

5.2 Análise por Acréscimo de Repetições:

Para visualizar de maneira completa o que se pode extrair das soluções, são apresentados gráficos das evoluções por acréscimo de repetições de todas as opções de número de gerações.


A expectativa para essa parte da análise é observar, para cada cenário de gerações do código, se o acréscimo de repetições mostra anomalias que comprometam a resposta do código executado apenas uma vez. Nesta parte, um indicador que será visualmente muito importante será o “range”, se houver uma grande variação do entre os espaçamentos naturais do gráfico, entre max, med e min, mostrará que em certos casos o desempenho pode sair do esperado.

- 1 Geração:

Tabela 10: Resultados para 1 geração.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
10	1	0.95	0.34	0.65	0.4729	0.4602	0.4660
30	1	1.22	0.21	0.64	0.4783	0.4602	0.4669
70	1	1.93	0.24	0.70	0.4786	0.4602	0.4668
150	1	5.82	0.41	1.28	0.4798	0.4602	0.4658
300	1	2.21	0.19	0.60	0.4813	0.4602	0.4660


Gráfico 11: Código 1 Geração - Repetições x Tempo.



Fonte: Próprio Autor

O gráfico mostra uma constância admissível entre as repetições, principalmente entre Tmin e Tmed, com exceção das 150 repetições, que mostram uma forte anomalia para Tmax e uma pequena deformação para Tmin e Tmed, o que pode mostrar que nessa bateria de testes houve ou houveram resultados totalmente fora do esperado.

Gráfico 12: Código 1 Geração - Repetições x Hipervolume.



Fonte: Próprio Autor


Neste há uma boa constância nos resultados, apesar do grande espaçamento entre os indicadores e o baixo desempenho na escala.

- 5 Gerações:

Tabela 11: Resultados para 5 gerações.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
10	5	4.89	2.14	3.19	0.4932	0.4801	0.4864
30	5	4.74	1.99	3.24	0.4938	0.4653	0.4849
70	5	6.02	2.06	3.68	0.4925	0.4634	0.4830
150	5	6.96	1.70	3.34	0.4931	0.4625	0.4839
300	5	12.03	2.43	6.35	0.4934	0.4647	0.4831


Gráfico 13: Código 5 Gerações - Repetições x Tempo.



Fonte: Próprio Autor

Novamente um acréscimo no espaçamento entre os indicadores, mostrando possíveis inconstâncias nesse processo quando visto de maneira repetida.

Gráfico 14: Código 5 Gerações - Repetições x Hipervolume.



Fonte: Próprio Autor


Há quase uma constância entre o Tmax e o Tmed e os valores absolutos evoluem na escala, no entanto as repetições mostram muitos péssimos resultados, provavelmente remanescentes da ainda baixa quantidade de gerações.

- 10 Gerações:

Tabela 12: Resultados para 10 gerações.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
10	10	11.24	5.06	6.85	0.4932	0.4757	0.4894
30	10	9.63	4.85	6.98	0.4943	0.4779	0.4883
70	10	14.10	5.15	7.72	0.4954	0.4776	0.4885
150	10	25.50	4.38	8.90	0.4949	0.4723	0.4885
300	10	22.88	7.27	12.38	0.4950	0.4679	0.4882


Gráfico 15: Código 10 Gerações - Repetições x Tempo.



Fonte: Próprio Autor

A inconstância e a variação do “range” é forte e crescente. Este gráfico é uma versão extremamente ruidosa do primeiro caso, reforçando as anomalias nos maiores números de repetições.

Gráfico 16: Código 10 Gerações - Repetições x Hipervolume.



Fonte: Próprio Autor


Neste percebe-se uma evolução no Tmin em relação ao cenário anterior, mostrando de maneira paralela a evolução pelo acréscimo de gerações. Houve uma aproximação entre os indicadores em relação ao cenário anterior, mas ainda há uma variação no “range”, principalmente a partir das 70 repetições, e um desempenho quase decrescente do Tmin.

- 20 Gerações:

Tabela 13: Resultados para 20 gerações.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
10	20	17.22	12.63	14.81	0.4948	0.4896	0.4925
30	20	23.78	12.11	16.12	0.4952	0.4854	0.4912
70	20	23.32	9.89	15.61	0.4954	0.4862	0.4917
150	20	21.93	9.28	13.64	0.4976	0.4817	0.4920
300	20	38.10	9.43	19.91	0.4983	0.4836	0.4919


Gráfico 17: Código 20 Gerações - Repetições x Tempo.



Fonte: Próprio Autor

Como visto na própria análise por acréscimo de gerações, o fator tempo apresenta uma aleatoriedade grande e, de acordo com os gráficos dessa seção, é de “range” crescente, mas extremamente ruidoso.

Gráfico 18: Código 20 Geração - Repetições x Hipervolume.




Fonte: Próprio Autor

É possível concluir que a partir da geração 20 o Tmin evoluiu suficientemente para entrar em uma faixa mais constante de “range” com os outros indicadores. Neste momento, pode-se presumir que haverá uma possível evolução desse espaçamento nos próximos cenários.

- 40 Gerações:


Tabela 14: Resultados para 40 gerações.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
10	40	29.11	22.49	26.25	0.4958	0.4912	0.4938
30	40	35.08	25.60	29.52	0.4970	0.4907	0.4940
70	40	81.78	22.36	48.29	0.4985	0.4896	0.4935
150	40	79.94	22.42	42.06	0.4963	0.4903	0.4937
300	40	32.53	20.54	25.54	0.4980	0.4899	0.4938



Novamente uma anomalia no centro do gráfico, de maneira isolada nas repetições 70 e 150. Isso deixa a leitura inconclusiva quanto às repetições, visto que em 300 repetições os indicadores voltam a ter um “range” pequeno. A dispersão dos indicadores observados por esse gráfico está se mostrando aleatória e não mais crescente, caindo exclusivamente sobre o desempenho do hardware.

Gráfico 20: Código 40 Gerações - Repetições x Hipervolume.




Como previsto no cenário anterior, a evolução dos indicadores faz o “range” reduzir, mas o acréscimo de repetições começa a mostrar uma possível estagnação na redução desse espaçamento, isso pode justificar a não necessidade de executar o código diversas vezes para obter um resultado que não seria obtido com uma ou poucas tentativas, caso o código tenha gerações o suficiente para ser assertivo.

- 80 Gerações:

Tabela 15: Resultados para 80 gerações.

Repetições	Gerações	Tmax	Tmin	Tmed	Hmax	Hmin	Hmed
10	80	70.92	57.08	65.73	0.4969	0.4943	0.4953
30	80	77.42	55.55	64.02	0.4979	0.4924	0.4951
70	80	148.23	68.20	116.29	0.5004	0.4913	0.4953
150	80	139.26	49.20	79.63	0.4988	0.4918	0.4952
300	80	136.62	47.22	60.58	0.5001	0.4912	0.4952


Gráfico 21: Código 80 Gerações - Repetições x Tempo.



Fonte: Próprio Autor

Neste há uma confirmação da aleatoriedade citada no cenário anterior. Sendo assim, o acréscimo de repetições apenas aumenta a chance de capturar essas anomalias causadas pelo desempenho do hardware.

Gráfico 22: Código 80 Gerações - Repetições x Hipervolume




Fonte: Próprio Autor

Por fim, houve outra aproximação entre os indicadores, principalmente nos primeiros pontos de repetição, confirmando a evolução da melhor solução até 70 repetições. Esse fato mostra que até esse ponto poderiam haver melhores soluções a serem encontradas, mas o valor médio se manteve praticamente constante, como em todos os outros cenários anteriores.

- **Visualização das modificações**


Para facilitar a visualização da mudança proposta, as figuras a seguir mostrarão o cenário de cargas sem otimização e com otimização, em que as barras representam as cargas, que preenchem horários e níveis de potência, a linha vermelha representa a demanda máxima para a manutenção do valor pago pela energia em uma faixa constante e a linha azul representa o padrão de consumo naquela hora. Visto que o cenário de melhor desempenho nos tópicos anteriores foi o de valor máximo de gerações, este será ilustrado:

Gráfico 23 – Arranjo de cargas sem otimização.



Fonte: Próprio Autor

Gráfico 24: Arranjo de cargas com otimização.



Fonte: Próprio Autor

CAPÍTULO 6

6. Conclusão

Diante do exposto, pode-se concluir que houve uma diferenciação quanto à qualidade dos resultados obtidos pela diferença entre indicadores, incremento do código e quantidade de vezes que o código foi executado. Para o código proposto, o fator aleatoriedade é presente em muitos pontos, o que é necessário para manter a variedade das soluções, e isso pode acabar comprometendo a diferença entre resultados que têm suas entradas muito próximas. Com isso, a visão macro dos resultados facilita a interpretação e a tirada de conclusões.

Houve um progresso dos indicadores com o acréscimo de gerações e uma maior confiabilidade do resultado com o acréscimo das repetições. Para o indicador tempo, o ruído em virtude da aleatoriedade e do desempenho do hardware esteve fortemente presente, mas recorrendo à análise macro foi visto que o incremento de gerações provoca um forte aumento de tempo, que aos poucos vai perdendo a linearidade e se torna cada vez mais inclinado, de forma que passa a necessitar de mais tempo, de acordo com os gráficos do capítulo passado, isso foi observado principalmente após às 40 gerações. Para o incremento de repetições, houve apenas um acréscimo do ruído em contraponto a poucos melhores resultados.

Para o indicador de hipervolume, as melhoras com o acréscimo de gerações foram expressivas, no melhor resultado, no resultado médio, no pior resultado e na constância das soluções; essa melhora é observada em todos os gráficos do capítulo anterior referente aos acréscimos de gerações. Para o acréscimo de repetições, houve uma conclusão indireta sobre o acréscimo de gerações, visto que o gap entre as soluções foi sendo cada vez mais reduzido. No entanto, para o objetivo de melhora através das repetições, foi observado que as melhores e piores soluções flutuam sem relação lógica nos intervalos indicados, mas o valor médio, que também flutua nos primeiros gráficos, se mostra constante em cenários que são utilizadas mais gerações. Esses resultados mostram que para um cenário macro em que são utilizadas gerações o suficiente, mais que 40 gerações para este estudo, o acréscimo de repetições tem resultado médio constante e melhores e piores resultados flutuantes.

Por fim, de todos os cenários estudados, o que trará melhores resultados será o

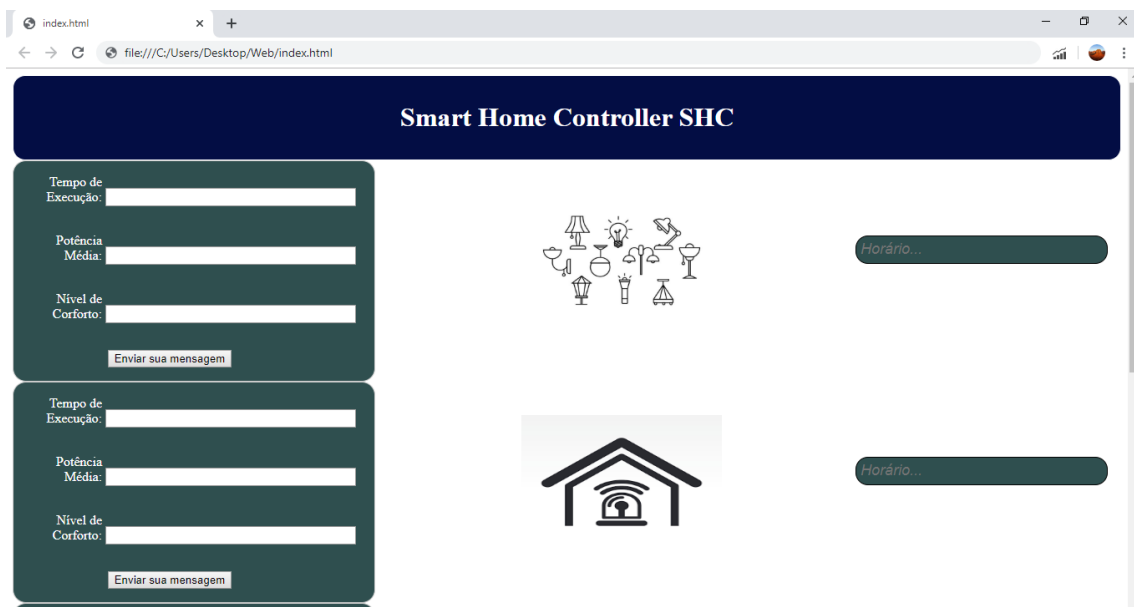
que dispor de mais recursos para o acréscimo de geração, em detrimento do tempo de execução de um código e do tempo que seria gasto com a execução repetida do mesmo código.

6.1 Trabalhos Futuros

O próximo passo é de expandir as possibilidades implementação, traduzindo para linguagens de programação mais acessíveis a diferentes tipos de hardware, como python. Já foi desenvolvido um material para realizar a tradução para python.

Além disso, para interação facilitada, está sendo desenvolvida uma interface *web* para receber as entradas do código que serão processadas no hardware.

Figura 13: Interface web - SHC



Fonte: Próprio Autor

REFERÊNCIAS

ANTUNES C. H.; HENRIQUES C. O., *Multi-Objective Optimization and Multi-Criteria Analysis Models and Methods for Problems in the Energy Sector in Multiple Criteria Decision Analysis*, J. Figueira, S. Greco, M. Erghott (Eds.). Springer. 2014.

ANTUNES, C. H.; MARTINS, A. G.; BRITO, I. S. *A multiple objective mixed integer linear programming model for power generation expansion planning*. Research Report no. 9, INESC Coimbra. 2002.

ANVARI-MOGHADDAM, A.; MONSEF, H.; RAHIMI-KIAN, A. *Optimal Smart Home Energy Management Considering Energy Saving and a Comfortable Lifestyle*, **IEEE trans. Smart Grid**. v. 6, n. 1, p. 324-332, janeiro, 2015.

BEAUDIN, M.; ZAREIPOUR, H. *Home Energy Management Systems: A Review of Modelling and Complexity*, Energy Solutions to Combat Global Warming. 2017.

BEZERRA, J. R.; BARROSO, G. C.; LEÃO, R. P. S.; SAMPAIO, R. F.; MEDEIROS, E. B.

Power Distribution Network Planning Application Based on Multi-Objective Binary Particle Swarm Optimization Algorithm. In: Ying Tan; Yuhui Shi; Hongwei Mo. (Org.). Lecture Notes in Computer Science - Advances in Swarm Intelligence. 1ed. Berlin: Springer- Verlag, v. 7928, p. 258-267, 2013

BEGOVIC M..*Smart Homes Energy and Technology fuse together*. **IEEE power & energy magazine**. Outubro, 2013.

BEZERRA, J. R.; BARROSO, G. C.; LEÃO; R. P. S. *Switch Placement algorithm for reducing customers outage impacts on radial distribution networks*. In TENCON 2012. IEEE Region 10 Conference, p, 1–6, 2012.

BEZERRA FILHO, P. T. F.; ALBUQUERQUE, P. U. B.; PRATA, B. A.; BARROSO, G. C.

A smart home controller using an integer programming approach for the optimization of consumer economic saving and comfort. XII SBAI – Simpósio brasileiro de Automação Inteligente, Natal, Outubro, 2015.

CARREIRO, A. M. Energy *Smart House Architecture for a Smart Grid Energy Box System Solution Proposal*. Dissertação de Mestrado em Energia para a Sustentabilidade da Universidade de Coimbra, 2011.

CASELLA, I. R. S.; SANCHES, B. C. S.; SGUAREZI FILHO, A. J.; CAPOVILLA, C. E. A

Dynamic Residential Load Model Based on Non-homogeneous Poisson Process.

Journal of Control, Automation and Electrical Systems, 2016.

CHO, S. S. *Energy-Efficient Smart Home System: Optimization of Residential Electricity Load Management System*. Syracuse University Honors Program Capstone Projects. Paper 81. Maio, 2013.

Horário de Pico, **CPLF Energia**, 2019. Disponível em: <https://www.cplf.com.br/energias-sustentaveis/eficiencia-energetica/uso-consciente/Paginas/horario-de-pico.aspx>. Acesso em: 04 de mar. de 2019.

LAU, Lucas. Entenda as modalidades de tarifa de energia elétrica. **SHAREENERGY**, 2017. Disponível em: <http://shareenergy.com.br/entenda-as-modalidades-de-tarifa-de-energia-eletrica/>. Acesso em: 04 de mar. de 2019.

Energia elétrica com conforto e economia, **Secovi-PR**, 2015. Disponível em: <http://www.secovipr.com.br/Energia-eletrica-com-conforto-e-economia-104-5010.shtml>. Acesso em: 04 de mar. de 2019.

NEIVA, Daniele. Casas inteligentes: mais segurança, conforto e economia de energia. **Extra Globo**, 2010. Disponível em: <https://extra.globo.com/noticias/saude-e-ciencia/casas-inteligentes-mais-seguranca-conforto-economia-de-energia-642468.html>. Acesso em: 04 de mar. de 2019.

Smart Home: Você tem ideia do que é isso?, **Novva Aprimatic**, 2015. Disponível em: <https://www.novvaaprimatic.com.br/blog/smart-home-voce-tem-ideia-do-que-e-isso/>. Acesso em: 04 de mar. de 2019.

Smart Home ou Casa Inteligente: Tudo o que o mercado imobiliário precisa saber!, **Marketingimob**, 2016. Disponível em: <http://www.marketingimob.com/2016/09/smart-home-automacao-residencial.html>. Acesso em: 04 de mar. 2019.

Saiba o que é uma smart house e entenda a tendência do futuro, **imovelweb**, 2017. Disponível em: <https://www.imovelweb.com.br/noticias/sem-categoria/saiba-o-que-e-uma-smart-house-e-entenda-tendencia-futuro/>. Acesso em: 04 de mar. de 2019.

BRADLEY, Dawson. *Mechatronics, Electronics in products and processes*, Chapman and Hall Verlag, London, 1991.

NISE, Norman S. *Engenharia de Sistemas de Controle*. 6º Ed. LTC, Rio de Janeiro, 2012.

ALBUQUERQUE, Pedro U. B. **Estudo e desenvolvimento de abordagens multiobjetivo baseadas em programação linear e em metaheurísticas para otimização do custo com energia elétrica e do conforto do usuário**. Tese de Doutorado em Engenharia de Teleinformática da Universidade Federal do Ceará, 2018.

PRATA, B. de A. **Uma nova abordagem para a programação integrada de veículos e tripulações**. Tese de doutorado em Engenharia Industrial e Gestão da Faculdade de Engenharia da Universidade do Porto, 2011.

LACERDA, Estéfane G. M. **Algoritmos Genéticos: Aspectos Práticos**. DCA/UFRN, 2009.

LACERDA, Estéfane G. M. **Introdução aos Algoritmos Genéticos**. Disponível em: <https://www.dca.ufrn.br/~estefane/metaheuristicas/ag.pdf>. Acesso em: 14 de jul. de 2017.