

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Daniel Pegoraro Bertineti

**APLICAÇÃO DE MÉTODO DE DESLOCAMENTO DE CARGA PARA
SISTEMAS DE GERENCIAMENTO DE ENERGIA**

Santa Maria, RS
2019

Daniel Pegoraro Bertinetti

APLICAÇÃO DE MÉTODO DE DESLOCAMENTO DE CARGA PARA SISTEMAS DE GERENCIAMENTO DE ENERGIA

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração em Processamento de Energia, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Engenharia Elétrica**.

ORIENTADORA: Prof.^a Luciane Neves Canha

Santa Maria, RS
2019

Bertineti, Daniel Pegoraro
Aplicação de método de deslocamento de carga para
sistemas de gerenciamento de energia / Daniel Pegoraro
Bertineti.- 2019.
120 p.; 30 cm

Orientadora: Luciane Neves Canha Canha
Dissertação (mestrado) - Universidade Federal de Santa
Maria, Centro de Tecnologia, Programa de Pós-Graduação em
Engenharia Elétrica, RS, 2019

1. Redes inteligentes 2. Agendamento de carga 3.
Custo 4. PAPR 5. Otimização I. Canha, Luciane Neves Canha
II. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

©2019

Todos os direitos autorais reservados a Daniel Pegoraro Bertineti. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

Endereço: Ares Alegre. 1º Distrito (Interior - s/nº) Canguçu/RS.

Fone (0xx) 53 98131 8910; End. Eletr.: dbertineti@gmail.com

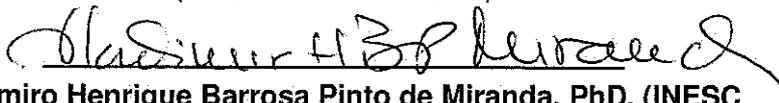
Daniel Pegoraro Bertineti

APLICAÇÃO DE MÉTODO DE DESLOCAMENTO DE CARGA PARA SISTEMAS DE GERENCIAMENTO DE ENERGIA

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração em Processamento de Energia, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Engenharia Elétrica**.

Aprovado em 20 de dezembro de 2019:

Luciane Neves Canha, Dr. (UFSM)
(Presidenta/Orientadora)



Vladimiro Henrique Barrosa Pinto de Miranda, PhD. (INESC PORTO) (videoconferência)

Camilo Alberto Sepulveda Rangel, Dr. (UFSM)

Santa Maria, RS
2019

DEDICATÓRIA

Aos meus pais Telmo e Nica e as minhas irmãs Elizane e Elizângela

AGRADECIMENTOS

A caminhada até a concretização deste trabalho ocorreu, principalmente, pelo auxílio, compreensão e dedicação de várias pessoas. Agradeço a todos que de alguma forma contribuíram para conclusão deste trabalho e, de uma maneira especial, agradeço:

- à minha orientadora, professora Luciane Neves Canha, pela oportunidade concedida no Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Maria. Também, por todo apoio, incentivo e orientação na construção desta dissertação;

- aos meus pais Telmo, Rosa e minhas irmãs que nunca mediram esforços para que pudesse alcançar este objetivo, me apoiando, incentivando e muitas vezes abrindo mão de seus próprios sonhos em prol do meu, amo vocês.

- ao amigo Bruno Fontana, por toda amizade, apoio nos estudos e trabalhos que desenvolvemos ao longo destes últimos anos, aprendi muito contigo nesse período e com certeza este trabalho é fruto de tua colaboração.

- ao amigo Aerton Medeiros, de tantos momentos juntos desde a graduação em Engenharia Elétrica, obrigado pelos incentivos, discussões e apoio.

- ao amigo Yuri Valadão, pela parceria ao longo dos últimos anos, desde a engenharia elétrica até as infundáveis discussões no downtown.

- aos amigos Rodrigo Motta de Azevedo, Charles Marques de Farias, Wagner Brignol e Pedro Alves, pelo apoio nos estudos, pela amizade e pela parceria nas viagens Pelotas x Santa Maria, sem vocês essa tarefa teria sido muito difícil.

- Ao amigo Márcio e Pedro Adão, vocês foram incríveis ao longo da minha caminhada e serei eternamente grato.

- a professora da extinta escola Coronel Genes Bento, aos professores da Escola Garibaldi, aos professores da Escola Técnica Canguçu, aos professores do Instituto Federal Sul-rio-grandense, aos professores da Universidade Federal de Pelotas, saibam que vocês fizeram parte desta caminhada e para sempre serão lembrados.

- aos professores e funcionários do Programa de Pós-Graduação em Engenharia Elétrica por contribuírem para manter a programa de pós-graduação conceito 6 (seis) CAPES.

- aos amigos (Juliano, Diego e Benhur) que sempre estiveram ao meu lado, vocês foram o refúgio nos momentos mais difíceis e sempre estiveram ao meu lado.

Enfim a todos àqueles que participaram desta caminhada.

*Toda grande caminhada começa com
um simples passo*

(Buda)

RESUMO

APLICAÇÃO DE MÉTODO DE DESLOCAMENTO DE CARGA PARA SISTEMAS DE GERENCIAMENTO DE ENERGIA

AUTOR: Daniel Pegoraro Bertineti
ORIENTADORA: Luciane Neves Canha

No contexto dos avanços esperados com a implantação das redes elétricas inteligentes e considerando a modernização das formas de sistema de tarifação de energia elétrica a relação entre usuário e o gerenciador do sistema elétrico passa a ter um relação diferenciada. O usuário passa a ser um agente ativo e seu comportamento passa a ter grande importância no comportamento da rede elétrica. Os fatores de custo para o lado do usuário e a sobrecarga sobre a rede de distribuição são fatores de suma importância para estes entes envolvidos e a utilização da técnica de deslocamento de carga (*Loading shifting*) é uma alternativa para que ocorra o equilíbrio entre estes fatores. Diante deste desafio, nesta dissertação é apresentada metodologia para realizar o agendamento de carga através de uma função objetivo que considera as métricas de custo e relação da potência de pico para potência média (PAPR), o modelo considera uma combinação linear convexa entre as duas métricas. A modelagem considera períodos de restrições para o agendamento de equipamentos que venham atender os interesses do usuário e todas as cargas são agendadas. Como forma de solução para o agendamento e com objetivo de obter-se uma resposta rápida para o agendamento foram implementados 3 métodos: método de solução única com busca local no estilo *Greedy Search*, o método de enxame de partículas (*Particle Swarm Optimization - PSO*) e o método de enxame de partículas evolutivas (*Evolutionary Particle Swarm Optimization - EPSO*). Para validar a implementação dos métodos na modelagem proposta são realizadas simulações considerando cenários com diversas cargas, com dois modelos tarifários diferentes e para diferentes coeficientes da combinação linear convexa. Neste trabalho apresenta-se uma comparação entre os resultados nos 3 métodos implementados e conclui-se que o EPSO mostrou-se mais eficiente para esta modelagem no cenário com maior número de cargas.

Palavras-chave: Redes inteligentes. Agendamento de carga. Custo. PAPR. Otimização.

ABSTRACT

LOAD SHIFT METHOD FOR RESIDENTIAL POWER MANAGEMENT SYSTEMS

AUTHOR: Daniel Pegoraro Bertineti

ADVISOR: Luciane Neves Canha

In the context of expected advances with the implementation of smart grids and considering the modernization of the forms of the electricity billing system in the relationship between user and manager of the electric system goes through a differentiated relationship. The user becomes an active agent and his behavior becomes of great importance in the behavior of the electric network. The cost factors for the user side and the overload on the distribution network are extremely important factors for these involved and the use of the load shifting technique is an alternative for the balance between the factors. Given this challenge, this dissertation presents methodology for load scheduling through an objective function that considers the cost and peak power to average power (PAPR) metrics, the model considers a convex linear combination between the two metrics. In the modeling is considered periods of restrictions for scheduling equipment that will meet the interests of the user and all loads are scheduled. As a solution to the scheduling and aiming to obtain a quick response to the scheduling, 3 methods were implemented, being a unique solution method in Greedy Search style, the method Particle Swarm Optimization - PSO and Evolutionary Particle Swarm Optimization - EPSO. To validate the implementation of the methods in the proposed modeling, simulations are performed considering scenarios with different loads and two different tariff models, for different coefficients of convex linear combination. This work presents a comparison between the results in the 3 implemented methods and concludes that EPSO was more efficient for this modeling.

Keywords: Smart grids. Load Scheduling. Cost. PAPR. Optimization.

LISTA DE FIGURAS

| | |
|---|----|
| Figura 2.1 – Técnicas de gerenciamento de carga | 30 |
| Figura 2.2 – Cenário de rede elétrica inteligente. | 32 |
| Figura 2.3 – Esquemas de preços variáveis no tempo: a) <i>ToU</i> , b) <i>CPP</i> e c) <i>RTP</i> | 34 |
| Figura 2.4 – Exemplo didático para o deslocamento de carga | 35 |
| Figura 2.5 – Crescimento do número de conexões de geração fotovoltaica após REN n° 482. | 36 |
| Figura 2.6 – Curva de geração fotovoltaica em p.u, considerando um dia típico de operação do sistema. | 37 |
| Figura 2.7 – Interpretação geométrica do <i>PSO</i> | 43 |
| Figura 2.8 – Topologia estrela aplicada ao <i>PSO</i> | 45 |
| Figura 2.9 – Ilustração da regra do movimento <i>EPSO</i> | 47 |
| Figura 3.1 – Importância do peso adotado para as métricas consideradas | 53 |
| Figura 3.2 – Referência utilizada para gerar o vetor de deslocamento \mathbf{E} ao longo da execução do algoritmo | 59 |
| Figura 4.1 – Modelo de tarifa aplicado nas simulações, inversamente proporcional à curva de geração fotovoltaica. | 66 |
| Figura 4.2 – Modelo de tarifa aplicado nas simulações, Tarifa Branca. | 67 |
| Figura 4.3 – Simulação para $N = 10$, $z = 1$, levando em consideração somente a métrica de custo para os três métodos implementados. Tarifa inverso a curva de geração PV. | 70 |
| Figura 4.4 – Simulação para $N = 10$, $z = 0$, levando em consideração somente a métrica de custo para os três métodos implementados. Tarifa inversa a curva de geração PV. | 71 |
| Figura 4.5 – Simulação para para os 3 métodos implementados com z variando no intervalo $0 \leq z \leq 1$ com passo 0.05 e $N = 10$ equipamentos. Tarifa inversamente proporcional à curva de geração fotovoltaica (PV). | 73 |
| Figura 4.6 – Simulação para os 3 métodos com $z = 0,25$ e $N = 10$. Tarifa inversamente proporcional à curva de geração PV. | 74 |
| Figura 4.7 – Simulação para os 3 métodos com $z = 0.25$, repetindo a simulação 100 vezes para $N = 10$ | 75 |
| Figura 4.8 – Simulação para $N = 100$ e $z = 1$, levando em consideração somente a métrica de custo para os três métodos implementados. Tarifa inversamente proporcional à curva de geração PV. | 76 |
| Figura 4.9 – Simulação com $N = 100$ e $z = 0$, considerando apenas a métrica de PAPR. Tarifa inversa a curva de geração fotovoltaica. | 77 |
| Figura 4.10 – Simulação para para os 3 métodos implementados com z variando a um passo 0.005. $0 \leq z \leq 1$, $N = 100$, Tarifa inverso à curva de geração PV. | 78 |
| Figura 4.11 – Simulação para os 3 métodos considerando o ponto de Pareto para o agendamento de $N = 100$ cargas. | 79 |
| Figura 4.12 – Simulação para os 3 métodos no ponto de pareto, repetindo a mesma simulação 100 vezes. $N = 100$ | 80 |
| Figura 4.13 – Simulação para os 3 métodos com considerando variação de z a um passo de 0.005, repetindo a simulação 100 vezes para cada peso em um cenário com $N = 100$ cargas e considerando tarifa branca. | 81 |
| Figura 4.14 – Simulação para o método <i>EPSO</i> no ponto de pareto considerando $z =$ | |

| | |
|--|-----|
| 0.035, $N = 100$ e tarifa branca | 82 |
| Figura 4.15 – Análise de resultados do custo considerando simulações com 100 cargas | 83 |
| Figura 4.16 – Análise de resultados do PAPR considerando simulações com 100 cargas | 84 |
| Figura 5.1 – Curva de carga real considerada | 87 |
| Figura 5.2 – Função objetivo para variações de pesos z , considerando 10 Cargas possíveis para o agendamento. Tarifa inversamente proporcional à uma curva de geração fotovoltaica. | 88 |
| Figura 5.3 – Estudo de caso com 10 cargas para tarifa inversa a uma curva de geração fotovoltaica | 89 |
| Figura 5.4 – Função objetivo para variações de peso com 70 cargas, considerando tarifa inversa à uma curva de geração fotovoltaica | 90 |
| Figura 5.5 – Estudo de caso com 70 cargas para tarifa inversa a uma curva de geração fotovoltaica | 91 |
| Figura 5.6 – Função objetivo para variações de pesos e 70 Cargas. Tarifa branca. ... | 91 |
| Figura 5.7 – Estudo de caso com 10 cargas para tarifa branca | 92 |
| Figura 5.8 – Análise de resultados do custo para estudo de caso considerando simulações com 70 cargas, tarifa inversa a curva PV | 93 |
| Figura 5.9 – Análise de resultados do PAPR para estudo de caso considerando simulações com 70 cargas, tarifa inversa a curva PV | 94 |
| Figura 5.10 – Análise de resultados do custo para estudo de caso considerando simulações com 70 cargas, tarifa branca | 95 |
| Figura 5.11 – Análise de resultados do PAPR para estudo de caso considerando simulações com 70 cargas, tarifa branca | 95 |
| Figura B.1 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 10 cargas aplicando o método deslocamentos aleatórios com solução única no estilo <i>Greedy Search</i> | 109 |
| Figura B.2 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 10 cargas aplicando PSO | 110 |
| Figura B.4 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR). Cenário com 10 cargas aplicando o método deslocamentos aleatórios com solução única no estilo <i>Greedy Search</i> | 110 |
| Figura B.3 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 10 cargas aplicando EPSO | 111 |
| Figura B.5 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR). Cenário com 10 cargas aplicando PSO | 111 |
| Figura B.6 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR). Cenário com 10 cargas aplicando EPSO | 112 |
| Figura B.7 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 10 cargas aplicando o método deslocamentos aleatórios com solução única no estilo <i>Greedy Search</i> | 112 |
| Figura B.8 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 10 cargas aplicando PSO | 113 |
| Figura B.9 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 10 cargas aplicando EPSO | 113 |
| Figura B.10 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 100 cargas aplicando o método deslocamentos ale- | |

| | |
|--|-----|
| atórios com solução única no estilo <i>Greedy Search</i> | 114 |
| Figura B.11 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 100 cargas aplicando PSO | 114 |
| Figura B.12 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 100 cargas aplicando EPSO | 115 |
| Figura B.13 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR). Cenário com 100 cargas aplicando o método deslocamentos aleatórios com solução única no estilo <i>Greedy Search</i> | 115 |
| Figura B.14 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR). Cenário com 100 cargas aplicando PSO | 116 |
| Figura B.15 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR). Cenário com 100 cargas aplicando EPSO | 116 |
| Figura B.16 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 100 cargas aplicando o método deslocamentos aleatórios com solução única no estilo <i>Greedy Search</i> | 117 |
| Figura B.17 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 100 cargas aplicando PSO | 117 |
| Figura B.18 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 100 cargas aplicando EPSO | 118 |
| Figura B.19 – Situação das cargas sem agendamento | 118 |
| Figura B.20 – Instante de agendamento de cargas para $z = 1$ (Somente métrica custo) para curva de carga real. Cenário com 70 cargas aplicando EPSO. | 119 |
| Figura B.21 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR) para curva de carga real. Cenário com 70 cargas aplicando EPSO. | 119 |
| Figura B.22 – Instante de agendamento de cargas para o ponto de Pareto para curva de carga real. Cenário com 70 cargas aplicando EPSO. | 120 |

LISTA DE TABELAS

| | |
|---|-----|
| Tabela 4.1 – Lista de cargas consideradas para o agendamento | 65 |
| Tabela 4.2 – Parâmetros <i>PSO</i> | 68 |
| Tabela 4.3 – Parâmetros <i>EPSO</i> | 68 |
| Tabela 4.4 – Resultado das métricas dos algoritmos considerando $z = 1$ | 69 |
| Tabela 4.5 – Horário de início de funcionamento das cargas considerando $z = 1$ | 70 |
| Tabela 4.6 – Resultado das métricas dos algoritmos considerando $z = 0$ | 72 |
| Tabela 4.7 – Horário de início de funcionamento das cargas considerando $z = 0$ | 72 |
| Tabela 4.8 – Resultado das métricas dos algoritmos considerando $z = 0.25$ | 74 |
| Tabela 4.9 – Resultado das métricas dos algoritmos para o cenário com 100 cargas, considerando $z = 1$ e Tarifa inversa a curva de geração fotovoltaica | 76 |
| Tabela 4.10 – Resultado das métricas dos algoritmos para o cenário com 100 cargas, considerando $z = 0$ e curva de tarifa inversamente proporcional à curva de geração fotovoltaica. | 77 |
| Tabela 4.11 – Resultado das métricas dos algoritmos para o cenário com 100 cargas, considerando ponto de Pareto para cada método. Curva de tarifa inversa a curva PV | 79 |
| Tabela 4.12 – Resultado das métricas para o ESPO no cenário com 100 cargas, considerando ponto de Pareto. Tarifa branca | 81 |
| Tabela 5.1 – Resultados obtidos para os agendamentos, considerando a condição inicial sem agendamento, com $z = 0$ (minimização de PAPR), com $z = 1$ (minimização de custo) e para o ponto de pareto | 89 |
| Tabela 5.2 – Resultados obtidos para os agendamentos, considerando a condição inicial sem agendamento, com $z = 0$ objetivo de minimização de PAPR, com $z = 1$ objetivo de minimização de custo e para o ponto de Pareto onde apresenta o ótimo para as duas grandezas | 92 |
| Tabela A.1 – Cargas consideradas para o agendamento no estudo de caso considerando uma curva de carga real | 105 |
| Tabela A.2 – Grupo de cargas para simulações. | 105 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|--------------|--|
| <i>GD</i> | Geração Distribuída |
| <i>PAPR</i> | Power Average Power Ratio |
| <i>SG</i> | Smart Grid |
| <i>RD</i> | Resposta a Demanda |
| <i>ANEEL</i> | Agência Nacional de Energia Elétrica |
| <i>ToU</i> | Time of Use |
| <i>HEMS</i> | Home Energy Management System |
| <i>CPP</i> | Critical Peak Pricing |
| <i>RTP</i> | Real Time Pricing |
| <i>REN</i> | Resolução Normativa |
| <i>PSO</i> | Particle Swarm Optimization |
| <i>EPSO</i> | Evolutionary Particle Swarm Optimization |
| <i>GA</i> | Genetic Algorithm |
| <i>BFA</i> | Bacterial Foraging Algorithm |
| <i>MSB</i> | Most Significant Bit |

SUMÁRIO

| | | |
|--------------|--|-----------|
| 1 | INTRODUÇÃO | 25 |
| 1.1 | CONSIDERAÇÕES INICIAIS | 25 |
| 1.2 | JUSTIFICATIVA | 26 |
| 1.3 | OBJETIVOS | 27 |
| 1.3.1 | Objetivo Geral | 27 |
| 1.3.2 | Objetivos Específicos | 27 |
| 1.4 | ESTRUTURA DO TRABALHO | 28 |
| 2 | REVISÃO BIBLIOGRÁFICA | 29 |
| 2.1 | O MUNDO SMART: A IMPORTÂNCIA DA <i>SMART GRID</i> E <i>SMARTHOMES</i> PARA A EVOLUÇÃO DO GERENCIAMENTO DA REDE ELÉTRICA | 31 |
| 2.2 | RESPOSTA À DEMANDA ATRAVÉS DO DESLOCAMENTO DE CARGA APLICADO A <i>SMART GRIDS</i> | 32 |
| 2.3 | O DESLOCAMENTO DE CARGA COMO ALTERNATIVA A SITUAÇÕES ATÍPICAS NA REDE | 35 |
| 2.4 | TÉCNICAS IMPLEMENTADAS PARA O AGENDAMENTO DE CARGAS | 36 |
| 2.5 | ESTUDO SOBRE MÉTODOS APLICADOS AO AGENDAMENTO DE CARGAS | 39 |
| 2.5.1 | Método de solução única com busca local no estilo <i>Greedy Search</i> | 40 |
| 2.5.2 | Método de otimização por Enxame de Partículas (<i>Particle Swarm Optimization - PSO</i>) | 41 |
| 2.5.3 | Método de otimização por Enxame de partículas evolutivas (<i>Evolutionary Particle Swarm Optimization - EPSO</i>) | 45 |
| 2.6 | RESUMO DO CAPÍTULO | 48 |
| 3 | MODELAGEM DO PROBLEMA PARA UM SISTEMA DE AGENDAMENTO DE CARGAS | 49 |
| 3.1 | MÉTRICAS ABORDADAS NA MODELAGEM | 49 |
| 3.1.1 | Custo de energia ao longo de um período | 49 |
| 3.1.2 | Razão da potência de pico para a potência média | 51 |
| 3.2 | CUSTO E PAPR ATRAVÉS DE COMBINAÇÃO LINEAR CONVEXA | 51 |
| 3.3 | MATRIZ DE AGENDAMENTO DE CARGA U | 53 |
| 3.3.1 | Transformação da matriz de agendamento de carga em um vetor | 54 |
| 3.4 | PROBLEMA DE OTIMIZAÇÃO DO AGENDAMENTO DE CARGA | 56 |
| 3.5 | APLICAÇÃO DE HEURÍSTICAS VISTO O AMPLO ESPAÇO DE BUSCA PARA O AGENDAMENTO DE CARGAS | 57 |
| 3.6 | ALGORITMOS IMPLEMENTADOS DE ACORDO COM A MODELAGEM PROPOSTA | 58 |
| 3.6.1 | Algoritmo de solução única com busca local para o agendamento de carga | 58 |
| 3.6.2 | Algoritmo <i>PSO</i> para o agendamento de carga | 60 |
| 3.6.3 | Algoritmo <i>EPSO</i> para o agendamento de carga | 62 |
| 3.7 | OPERAÇÕES DE ARREDONDAMENTO E CEIFAMENTO | 62 |
| 3.8 | RESUMO DO CAPÍTULO | 63 |
| 4 | SIMULAÇÕES APLICADAS PARA VALIDAÇÃO DOS MÉTODOS IMPLEMENTADOS | 65 |
| 4.1 | CONSIDERAÇÕES GERAIS | 65 |
| 4.2 | PARÂMETROS UTILIZADOS NOS ALGORITMOS | 68 |

| | | |
|----------|---|------------|
| 4.3 | RESULTADO DAS SIMULAÇÕES CONSIDERANDO CARGAS AGENDÁVEIS | 69 |
| 4.3.1 | Cenário A para o agendamento considerando um número reduzido de cargas | 69 |
| 4.3.1.1 | <i>Cenário A considerando $z = 1$ para F_{obj}</i> | 69 |
| 4.3.1.2 | <i>Cenário A considerando $z = 0$ para F_{obj}</i> | 71 |
| 4.3.1.3 | <i>Cenário A considerando $0 \leq z \leq 1$ para F_{obj}</i> | 72 |
| 4.3.1.4 | <i>Cenário A considerando $z = 0.25$ para F_{obj}</i> | 73 |
| 4.3.2 | Cenário B para o agendamento considerando um número maior de cargas e tarifa inversamente proporcional à geração do sistema fotovoltaico | 75 |
| 4.3.3 | Cenário C para o agendamento considerando um número maior de cargas e aplicando a tarifa branca | 80 |
| 4.4 | ANÁLISE DE RESULTADOS REFERENTE AOS 3 MÉTODOS IMPLEMENTADOS | 82 |
| 4.5 | RESUMO DO CAPÍTULO | 84 |
| 5 | ESTUDO DE CASO APLICADO | 87 |
| 5.1 | APLICAÇÃO DE EPSSO PARA 10 CARGAS | 88 |
| 5.2 | APLICAÇÃO DE EPSSO PARA 70 CARGAS | 90 |
| 5.3 | ANÁLISE RESULTADOS REFERENTE AO EPSSO APLICADO A AO ESTUDO DE CASO | 93 |
| 5.3.1 | Análise considerando tarifa inversa a uma curva fotovoltaica | 93 |
| 5.3.2 | Análise considerando tarifa branca | 94 |
| 5.4 | RESUMO DO CAPÍTULO | 95 |
| 6 | CONCLUSÃO | 97 |
| 6.1 | TRABALHOS FUTUROS | 98 |
| 6.2 | PUBLICAÇÕES REFERENTES AO TEMA DO TRABALHO | 99 |
| | REFERÊNCIAS BIBLIOGRÁFICAS | 101 |
| | APÊNDICE A – TABELAS DE CARGAS UTILIZADA NAS SIMULAÇÕES | 105 |
| | APÊNDICE B – INSTANTES DE TEMPO ONDE AS CARGAS FORAM AGENDADAS PARA CADA UM DOS CENÁRIOS | 109 |

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

Por algumas décadas, observa-se um crescimento exponencial na demanda de energia dos consumidores. Com este crescimento da demanda de energia percebe-se que o sistema elétrico como um todo está diante de desafios em relação à sua manutenção, sustentabilidade e confiabilidade.

Sabe-se que por muitos anos o formato de rede tradicional radial se manteve funcional e com grande importância para o sistema elétrico. Entretanto, a rede passou a ter a inserção de novas fontes de geração localizadas próxima a carga, principalmente devido ao crescimento da inserção de fontes de energias renováveis na matriz energética em nível mundial e à busca de diversos países por uma diversificação, com o objetivo de manter confiabilidade e segurança.

No Brasil, através da regulamentação da geração de energia distribuída (GD) e com a ampla oferta desta tecnologia para a implementação em ambientes residenciais, nota-se um crescimento exponencial da mesma, principalmente da geração de energia fotovoltaica, a qual atua de forma intermitente próximo a carga.

O crescimento de demanda, o desenvolvimento e evolução tecnológica, aliados ao crescimento de outras formas de geração, tornam-se fatores decisivos para que ocorra a modernização do sistema elétrico como um todo. Assim, as *Smart Grids* e *Smart homes* ganham destaque como paradigmas necessários na implementação de um sistema elétrico moderno.

Neste cenário, sabe-se que a rede elétrica inteligente permite que o sistema seja mais eficiente, confiável e sustentável. Um dos componentes importantes desta rede é o conjunto de casas inteligentes que fazem parte da mesma, onde encontram-se os dispositivos que, baseado em informações do sistema, podem participar do gerenciamento do lado da demanda.

Através da utilização de técnicas de gerenciamento pelo lado da demanda pode-se reduzir a demanda geral de pico de carga, remodelar o perfil de demanda e aumentar a sustentabilidade da rede, reduzindo o custo, níveis de emissão de carbono e tornando a rede mais eficiente.

Pode se dizer o gerenciamento pelo lado da demanda traz benefício ao usuário, através da redução de custos de consumo, e para o operador do sistema, através de reduções de pico em determinados períodos ao longo do dia. Neste sentido, a resposta à demanda (RD) representa mudanças no uso de eletricidade pelos clientes finais, motivando alterações de seus padrões de consumo em resposta aos sinais tarifários ao longo

do tempo. Neste aspecto, os programas de RD baseado em preços buscam mitigar os picos de demanda com o objetivo de tanto o cliente quanto a concessionária receberem benefícios devido as alterações de comportamento.

1.2 JUSTIFICATIVA

No Brasil, de acordo com a resolução normativa N° 414 da Agência Nacional de Energia Elétrica (ANEEL), de 09 de Setembro de 2010, que estabelece as condições gerais de fornecimento de Energia Elétrica de forma atualizada e consolidada, os consumidores residenciais são classificados como Grupo B, subgrupo B1.

Segundo a ANEEL, através de relatório anual de 2018, o consumo de energia elétrica pelo segmento do grupo B1 (residencial) representa 44.28 % da energia total consumida no Brasil.

Atualmente, no Brasil, a resolução normativa N° 733 de 06 de Setembro de 2016 estabelece as condições para a aplicação da modalidade tarifária horária branca. Nesta modalidade, é facultada aos usuários do Grupo B adesão a este modelo tarifário, o qual apresenta valores distintos ao longo do dia.

Considerando a existência atual de cenários de modelos tarifários que apresentam diferentes patamares ao longo do dia, acredita-se que, futuramente, outros modelos tarifários possam ser aplicados de acordo com as características da rede através de variações ao longo do dia. Essa perspectiva é fortalecida ao observarmos a evolução das redes elétricas e casas inteligentes, com a presença de cada vez mais dispositivos que podem ser conectados a rede.

Aliado a estes fatores tarifários, a utilização de estratégias de resposta à demanda no âmbito residencial requer a necessidade de lidar com um grande número de cargas, de vários tipos e características de atuação. Além disso, as cargas podem ter características diferentes quanto ao tempo de funcionamento e a simultaneidade. Portanto, as estratégias devem ser capazes de lidar com todas as durações possíveis de uma variedade de cargas controláveis, para que essas possam participar do gerenciamento.

Baseado nestas premissas, este trabalho propõe ir ao encontro de apresentar soluções referentes ao agendamento de cargas através de modelagem que possa tanto beneficiar o usuário quanto a distribuidora. Busca-se encontrar o equilíbrio entre duas métricas com características distintas, sendo elas o custo da energia para o usuário (cliente) e a redução de picos para o operador do sistema elétrico (distribuidora).

Em outras palavras, este trabalho propõe um sistema de gerenciamento de energia residencial que emprega a estratégia de gerenciamento pelo lado demanda, baseado no deslocamento de cargas, com o objetivo de otimizar os perfis de consumo de energia de uma casa inteligente, considerando sinais tarifários variáveis ao longo do dia.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Como objetivo geral, este trabalho pretende contribuir com a implementação de algoritmos para o agendamento de carga considerando cenários de *Smart Grids*. O objetivo é gerenciar a demanda de carga de maneira eficiente para minimizar o custo da eletricidade e a relação entre o pico e a média de consumo, mantendo o conforto do usuário por meio da coordenação entre os equipamentos. Considera-se o agendamento de carga para o dia seguinte e que o algoritmo possa ser implementado pela empresa distribuidora que agendará as cargas disponibilizadas pelo cliente para tal ação.

1.3.2 Objetivos Específicos

- (a) Analisar estratégias de gerenciamento pelo lado da demanda que possibilitem a implementação de técnicas de agendamento de cargas considerando a utilização de redes elétricas inteligentes e considerando a utilização do *Home Energy Management System*.
- (b) Desenvolver modelagem que possibilite que as cargas com características diferentes de tempo de atuação e com restrições de períodos de funcionamento possam ser agendadas, de acordo com um sinal tarifário, visando a manter um grau de conforto ao usuário.
- (c) Implementar métodos de otimização utilizando técnicas heurísticas para o agendamento de cargas, considerando a resposta à demanda baseada em sinais tarifários para o dia seguinte.
- (d) Encontrar a resposta quase-ótima da forma mais rápida possível considerando a modelagem e peso adotado para as métricas de custo e razão da potência de pico para a potência média.

1.4 ESTRUTURA DO TRABALHO

Este trabalho está organizado conforme a seguinte descrição.

No Capítulo 1 são apresentados a introdução, os objetivos gerais e específicos, bem como a organização do trabalho.

O Capítulo 2 apresenta uma revisão sobre o estado da arte referente as estratégias de gerenciamento pelo lado da demanda, resposta à demanda através de tarifas diferenciadas e visão geral sobre as *Smart Grids*. Apresenta ainda alternativas do agendamento de cargas referentes ao problema da *Duck-Curve*. Também é apresentada uma revisão bibliográfica referente ao tema dissertado e por fim conclui-se apresentando uma revisão sobre os métodos de otimização que foram implementados para agendamento de cargas neste trabalho.

O Capítulo 3 apresenta a modelagem matemática aplicada, bem como descrição dos algoritmos implementados, considerando as métricas de custo e potência de pico para a potência média.

O Capítulo 4 apresenta resultados das simulações comparando três métodos implementados para o agendamento de carga. Dois cenários são discutidos: agendamento de 10 de cargas e agendamento de 100 cargas. Para ambos os casos considerou-se tarifas variáveis. Ao final do capítulo é apresentada uma discussão sobre os resultados obtidos nas simulações.

Por fim no Capítulo 5 apresenta um estudo de caso considerando os dados reais de uma curva de carga que apresenta uma parcela de equipamentos que podem ser agendados. Neste estudo de caso, considera-se primeiramente um número reduzido de cargas e após um número maior. Nesta situação são apresentados os benefícios que podem ser obtidos para os envolvidos, através do agendamento de cargas.

2 REVISÃO BIBLIOGRÁFICA

O crescimento da demanda em energia elétrica, até a década de 1970, sempre foi considerado previsível e as companhias responsáveis realizavam o planejamento de sua capacidade de acordo com a previsão. Entretanto após este período foi observado a aceleração do crescimento da demanda por energia elétrica, assim constatou-se a necessidade da integração de metodologias de operação e planejamento com o objetivo de influenciar ativamente o gerenciamento da demanda de energia (GELLINGS, 1985).

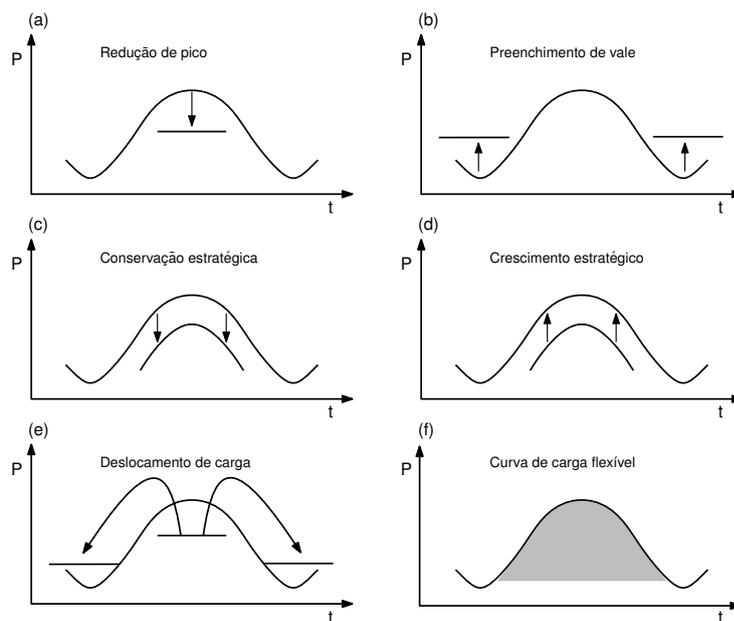
Segundo Gellings (1985), o Gerenciamento pelo Lado da Demanda (*DSM, Demand-Side Management*) também conhecido como *GLD*, é o planejamento, a implementação e o monitoramento das atividades utilitárias projetadas para influenciar o uso do cliente. É tratado em função de curvas de carga, onde a curva representa o comportamento diário ou sazonal da demanda de energia em função do tempo.

O gerenciamento de carga é dividido em seis categorias, conforme apresentado na Figura 2.1, sendo eles: redução de pico, preenchimento de vale, conservação estratégica, crescimento estratégico de carga, deslocamento de carga e curva de carga flexível. Segue uma breve descrição de cada categoria:

- (a) Redução de pico (do inglês *Peak Clipping*): Refere-se ao corte de carga em horários de pico, que em geral ocorre devido ao desligamento de cargas específicas ou inserção de geração distribuída local.
- (b) Preenchimento de vale (do inglês *Valley filling*): Esta estratégia busca promover o consumo fora do horário de pico, para momentos do dia que o custo de produção é menor. Entretanto, para sua aplicação, torna-se necessário a utilização de tarifas diferenciadas que busquem incentivar a utilização do consumidor.
- (c) Conservação estratégica (do inglês *Strategic Conservation*): Busca a redução estratégica do consumo, principalmente com ênfase no desperdício de energia. Ocorre a suavização de forma geral a curva de carga, mas para que isto ocorra muitas vezes é necessária a substituição de tecnologias e para isso é importante que se tenha incentivos.
- (d) Crescimento estratégico de carga (do inglês *Strategic Load Growth*): Controla o crescimento de carga através de inserção de equipamentos com requerida inteligência e eficiência energética.
- (e) Deslocamento de carga (do inglês *Load Shifting*): Desloca a demanda para momentos onde ocorre menor pico de carga. O consumo total permanece inalterado, entretanto em momentos diferentes do usual e isto pode ocorrer através da utilização de geração distribuída e tarifas diferenciadas.

- (f) Curva de carga flexível (do inglês *Flexible Load Shape*): Trata-se de um conceito relacionado à confiabilidade, uma restrição de planejamento. Suas ações seguem um plano integrado entre o consumidor e a concessionária, de acordo com a necessidade do momento. Limita o uso de energia de um consumidor durante certos momentos, sem afetar as condições reais de segurança, através da instalação dispositivos limitadores de carga, .

Figura 2.1 – Técnicas de gerenciamento de carga



Fonte: Adaptado de Gellings (1985)

Gellings (1985) definiu que o *DSM* inclui apenas as atividades que envolvem uma intervenção deliberada da concessionária no mercado, de modo a alterar a demanda do consumidor. Segundo esta definição, as compras de aparelhos energeticamente eficientes pelos clientes, em reação à necessidade percebida de conservação, não seriam classificadas como *DSM*.

Uma definição que merece destaque é a resposta à demanda (RD), que pode ser definida como alterações no uso de energia por parte dos consumidores finais e de seus padrões normais de consumo em resposta a mudanças no preço da eletricidade ao longo do tempo ou a pagamentos de incentivo projetados para induzir menor uso de eletricidade em momentos de altos preços no mercado atacadista ou quando a confiabilidade do sistema é comprometida (DU NING LU, 2019).

Recentemente, os interesses ressurgentes nas tecnologias de RD são motivados pelo avanço nas tecnologias de informação e comunicação e pela ampla implantação de monitoramentos. Os objetivos da RD também são ampliados para desenvolver todo o potencial dos recursos de geração distribuída (GD) de propriedade do cliente, fornecendo uma gama completa de serviços de rede.

2.1 O MUNDO SMART: A IMPORTÂNCIA DA *SMART GRID* E *SMART HOMES* PARA A EVOLUÇÃO DO GERENCIAMENTO DA REDE ELÉTRICA

Com o surgimento de novas tecnologias, equipamentos e com aumento na demanda de eletricidade, a rede elétrica tradicional está enfrentando vários desafios, como manutenção, sustentabilidade e confiabilidade.

Embora o tema de gerenciamento pelo lado da demanda e resposta à demanda seja discutido há muitos anos, com surgimento das redes elétricas inteligentes (*Smart Grids - SG*) este tema recebe um impulso, tornando possível a efetividade de ações no desenvolvimento de estratégias de maneira flexível e diversificada para manter um equilíbrio entre a geração e o consumo (SIEBERT et al., 2012; KHALID et al., 2018).

Segundo Logenthiran, Srinivasan e Shun (2012), as *Smart Grids* representam sistemas de energia que integram tecnologias avançadas de detecção, metodologias de controle e tecnologias de comunicação nos níveis de transmissão e distribuição. Elas possibilitam uma melhor coordenação e interação entre os diversos agentes, a fim de fornecer eletricidade de maneira inteligente e causando uma maximização da eficiência, confiabilidade e estabilidade.

O que se busca com as redes inteligentes é levar a tecnologia para o setor elétrico, que é um segmento de fundamental importância para todos os países, mas que teve pouco desenvolvimento nas últimas décadas.

Em uma infraestrutura de rede inteligente, as concessionárias de energia podem estabelecer tarifas variáveis, incentivando os clientes a ajustar suas cargas ao estado atual da rede. Os benefícios deste gerenciamento podem ser: através da possibilidade de integração de fontes de energia intermitentes, como a energia solar no nível de distribuição; resposta à demanda, onde os clientes serão incentivados a mudar suas cargas para fora do horário de pico; economia de energia, pois estudos sugerem que dar acesso de clientes a informações de consumo em tempo real produz economias significativas (CARON; KESIDIS, 2010).

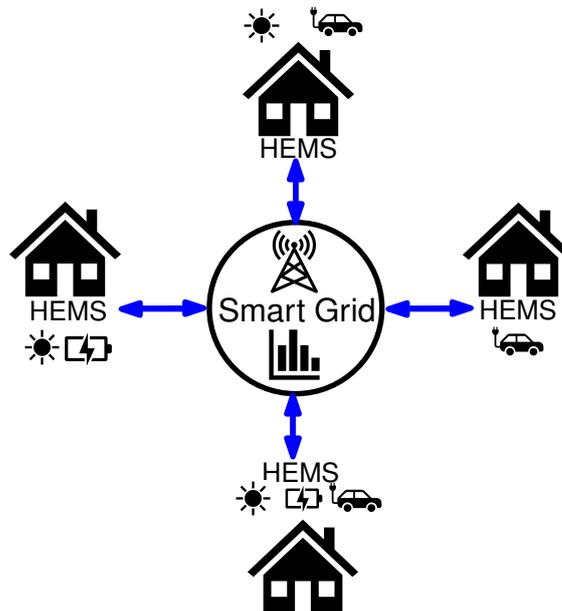
A Figura 2.2 ilustra de forma simplificada o conceito de uma rede elétrica inteligente.

No ambiente residencial, um componente importante e decisivo em uma rede inteligente refere-se ao *Home Energy Management Systems - HEMS*, que irá auxiliar no gerenciamento de energia residencial (TUSHAR; ZEINEDDINE; ASSI, 2018).

o *HEMS* é definido como o sistema para fornecer serviços de gerenciamento de energia, além de monitorar e gerenciar com eficiência a geração, o armazenamento e o consumo de eletricidade em casas inteligentes (*Smart Houses*). Ele pode fornecer apenas o melhor estado de utilização dos aparelhos domésticos, mas também o armazenamento de energia e os serviços de gerenciamento de fontes (GD).

Segundo Zhou et al. (2016), um sistema *HEMS* implementa muitas funções, sendo as cinco mais importantes: 1) Monitorar as condições de funcionamento de dispositivos

Figura 2.2 – Cenário de rede elétrica inteligente.



Fonte: Elaborada pelo autor

elétricos e mostrar informações importantes sobre seu consumo de energia; 2) Executar controle de demanda em função das alterações dos preços das tarifas de tempo real; 3) Controlar o funcionamento de equipamentos domésticos de maneira local ou remota; 4) Gerenciar a produção, armazenamento e consumo de energia elétrica; 5) Gerar e enviar sinais de alerta em caso de detecção de anomalias na residência.

2.2 RESPOSTA À DEMANDA ATRAVÉS DO DESLOCAMENTO DE CARGA APLICADO A SMART GRIDS

O elemento central dos esquemas de RD é a motivação dos clientes por meio de incentivos oferecidos pela empresa responsável pelo gerenciamento da rede para alteração do perfil de consumo de energia elétrica. A RD deve aumentar a conscientização do cliente sobre os benefícios de adotá-la e a importância da alteração do uso de eletricidade (HAIDER; SEE; ELMENREICH, 2016).

Em modo geral, os esquemas de resposta à demanda podem ser classificados em dois tipos: baseado em incentivos e baseado em preço.

Na categoria baseada em incentivos, os clientes são incentivados a reduzir seu consumo de energia mediante solicitação de ofertas ou de acordo com um contrato. Através do contrato, a empresa que administra o sistema possui autonomia para agendar ou desconectar cargas diretamente para reduzir custos. Recentemente, esses programas foram estendidos para cobrir clientes residenciais, além de clientes industriais e comerciais de

grande porte. A demanda instantânea e o estado operacional de dispositivos individuais são gerenciados usando controladores centralizados que realizam a decisão e a ação de controle (NIKZAD; MOZAFARI, 2014).

Na resposta à demanda baseada em preços, os clientes têm tarifas diferentes que refletem a avaliação e o custo da eletricidade por períodos diferentes. Através desta técnica, os usuários usam um processo distribuído de políticas de preços variáveis e são incentivados a gerenciar individualmente suas cargas, reduzindo ou mudando seu consumo de energia do horário de pico para o horário menos congestionado, favorecendo o balanceamento de carga (TORRITI, 2012).

Segundo Haider, See e Elmenreich (2016), são exemplos de programas resposta à demanda baseada em preço: *Time-of-use (ToU)*, *Critical peak pricing (CPP)* e *Real-time pricing (RTP)*. Segue uma breve descrição de cada exemplo:

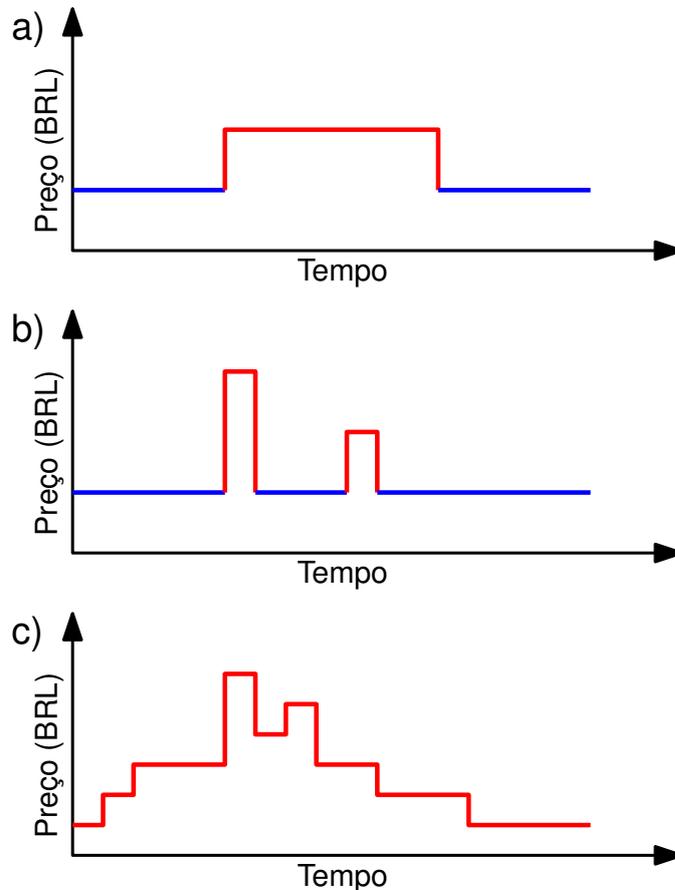
- *Time-of-use (ToU)*: Tarifa que reflete para os clientes as variações diárias e sazonais dos custos de eletricidade durante o horário de pico ou fora de pico. Eles são fixados antecipadamente e geralmente refletem o preço médio do fornecimento de eletricidade em determinados períodos.
- *Critical peak pricing (CPP)*: Apresenta semelhança com a tarifa *ToU*, com a adição de um preço de pico crítico que pode ser chamado diariamente. Esse momento pode variar ao longo de período ou época do ano.
- *Real-time pricing*: O preço em tempo real (*RTP*) fornece preços por hora para os clientes. Pode variar continuamente durante um dia. A *RTP* vincula preços por hora a alterações por hora em um custo de energia diário (em tempo real) ou no dia seguinte.

A Figura 2.3 apresenta os esquemas de preços variáveis no tempo.

Para que um sistema de RD se torne eficiente, é necessário que se implemente o agendamento e o gerenciamento de cargas dos clientes, de acordo com determinados critérios. Pode-se dizer então que o deslocamento de carga é uma técnica na qual a carga é gerenciada por meio de uma *RD*. Essa resposta à demanda pode ser realizada através de tarifas variáveis, que se alteram em diferentes períodos do dia, visando refletir situações típicas de fornecimento e demanda de energia, em intervalos fixos. (SIEBERT et al., 2012; HAIDER; SEE; ELMENREICH, 2016).

Através da utilização desta técnica, busca-se motivar os consumidores de eletricidade a mudarem seus padrões de consumo de energia com relação ao atual, através de sinais de preço, encorajando os consumidores a utilizar menos energia nas horas de maior carregamento e deslocar a carga para horários fora destes picos. Destaca-se que tal ação só é possível de ser implementada usando comunicação bidirecional, infra-estrutura de medição inteligente, com aparelhos inteligentes. (KHALID et al., 2018).

Figura 2.3 – Esquemas de preços variáveis no tempo: a) *ToU*, b) *CPP* e c) *RTP*.



Fonte: Adaptado de (HAIDER; SEE; ELMENREICH, 2016)

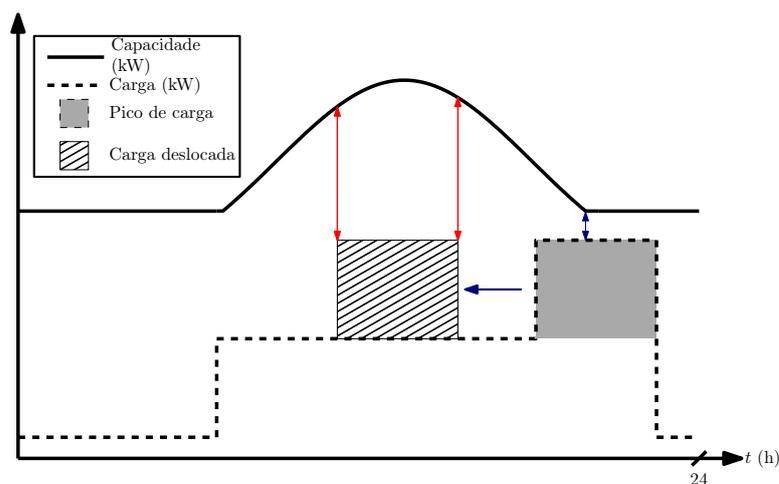
A Figura 2.4 ilustra uma situação de deslocamento de carga. A linha sólida mostra a capacidade de atendimento de carga do sistema, incluindo um aumento durante o dia, devido a grande penetração da energia renovável (por exemplo, fotovoltaica). A curva tracejada mostra a demanda de carga desses sistemas. Usando o gerenciamento de carga, é possível deslocar o consumo das cargas controláveis para preencher a lacuna durante o dia e reduzir a demanda nos horários de pico.

Quando empregada da forma correta, esta técnica pode representar benefícios para o cliente e para o gerenciador do sistema elétrico. Os consumidores obtêm incentivos através redução de custo na conta de energia elétrica enquanto o gerenciador pode reduzir o carregamento sobre a rede elétrica nos momentos de de maior demanda através da redução da razão da potência de pico para a potência média (*Peak-to-Average Power Ratio* - *PAPR*).

As alterações nos padrões de consumo de determinados equipamentos têm o objetivo de maximizar o uso de recursos de energia renovável, aumentando o benefício econômico, minimizando a energia importada de fonte não renovável da rede de distribuição e reduzindo a demanda de pico de carga (LOGENTHIRAN; SRINIVASAN; SHUN, 2012).

Para que ocorra o deslocamento, as cargas devem possuir características que pos-

Figura 2.4 – Exemplo didático para o deslocamento de carga



Fonte: Elaborado pelo autor

sibilitem tal atuação. De acordo diversos estudos, as cargas podem ser classificadas como cargas deslocáveis (*shiftable loads*) e cargas não deslocáveis (*non-shiftable loads*) (BERA; GUPTA; MISRA, 2015).

No ambiente residencial, as cargas deslocáveis são aquelas que podem ser agendadas em diferentes períodos de um dia, por exemplo, máquinas de lavar roupa, máquinas de lavar louça. Ainda, as cargas não deslocáveis são aquelas que devem ser operadas em horários específicos e sua alteração impacta diretamente no conforto do usuário ou até mesmo no ciclo de funcionamento do equipamento, por exemplo, iluminação, refrigeradores (HAIDER; SEE; ELMENREICH, 2016).

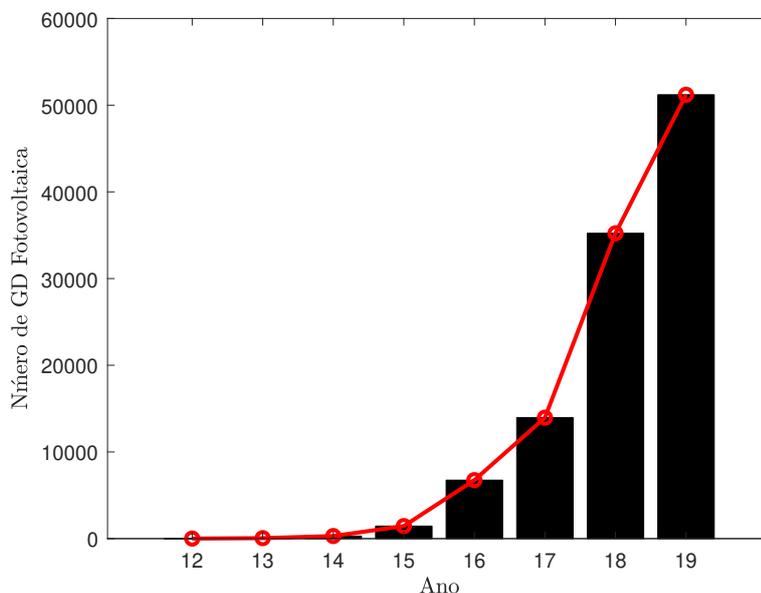
2.3 O DESLOCAMENTO DE CARGA COMO ALTERNATIVA A SITUAÇÕES ATÍPICAS NA REDE

No Brasil, a resolução normativa (REN) nº 482 de Abril de 2012, revisada e atualizada pela REN nº 687 de novembro de 2015, flexibilizou para a diversificação da matriz energética, ocasionando um crescimento de forma exponencial na penetração de geração fotovoltaica, conforme Figura 2.5 (ANEEL, 2019).

Considerando a característica da geração solar, que apresenta um perfil de geração variável ao longo do dia, e considerando a sua grande penetração, um fator que deve ser observado refere-se a *Duck-curve*, segundo dados publicados pelo Operador de Sistema Independente da Califórnia no ano de 2013 (DENHOLM et al., 2015).

Estes dados levantam preocupações de que o sistema de energia convencional não será capaz de acomodar a taxa de rampa e a faixa necessárias para utilizar totalmente a energia solar. Este fator embora apresente as suas vantagens, tem causado preocupações

Figura 2.5 – Crescimento do número de conexões de geração fotovoltaica após REN n° 482.



Fonte: ANEEL

referentes à rampa da curva de carga líquida do sistema de energia, a qual aumenta especialmente à noite, quando a produção fotovoltaica diminui e a demanda de carga elétrica aumenta ao mesmo tempo (DENHOLM et al., 2015).

Uma forma de amenizar essa variação causada pela *Duck-curve* pode ser utilizando as estratégias de respostas à demanda baseada em preços, que buscam alterar os padrões de consumo de clientes. Assim, através da utilização de uma tarifa com preço distinto ao longo do dia, pode-se incentivar os clientes à utilização nos períodos de menor custo.

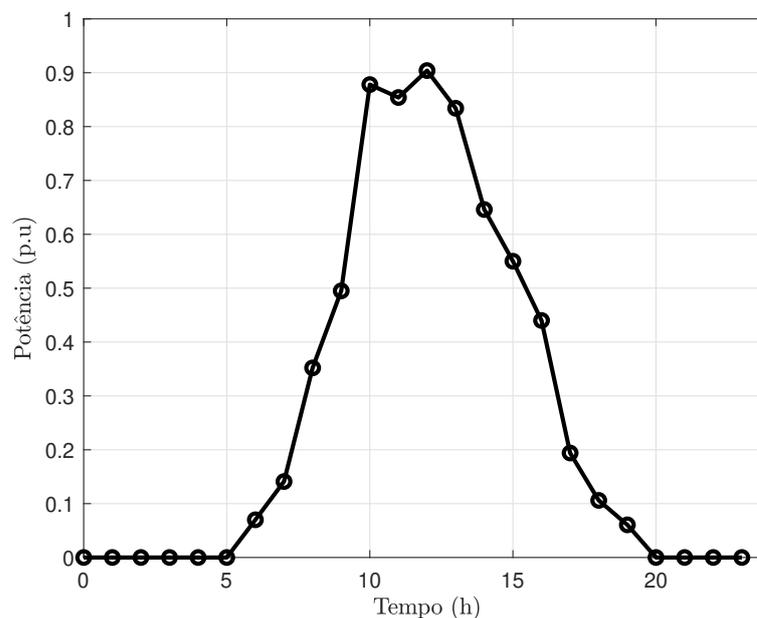
Sabendo que a curva de geração apresenta característica conforme descrita na Figura 2.6, uma tarifa que apresente um valor menor nos períodos de maior penetração de geração incentivará os clientes a deslocarem suas cargas para esses momentos de menor custo.

2.4 TÉCNICAS IMPLEMENTADAS PARA O AGENDAMENTO DE CARGAS

Para que ocorra a efetividade na realização do agendamento de cargas e que seja realizada de forma mais rápida possível, aplicam-se métodos de otimização com objetivo de encontrar a melhor solução para o problema de agendamento e apresentar a resposta de forma mais rápida possível.

Segundo Logenthiran, Srinivasan e Shun (2012), cada tipo de carga deslocável pode ter diferentes características de consumo, que se distribuem por alguns intervalos de

Figura 2.6 – Curva de geração fotovoltaica em p.u, considerando um dia típico de operação do sistema.



Fonte: Adaptado de Azevedo (2017)

tempo. Portanto, o algoritmo projetado deve ser capaz de lidar com essas complexidades e amplo espaço de busca para uma solução de agendamento.

A maioria dos esquemas de resposta à demanda necessitam de uma técnica de agendamento para o gerenciamento de cargas do cliente com base em flutuações de preço. O agendamento de equipamentos é uma das abordagens tecnológicas promissoras de redes inteligentes que tem o potencial de minimizar a *PAPR* da demanda da rede, ao mesmo tempo em que busca minimizar simultaneamente o custo de energia para os clientes (SIEBERT et al., 2012; BERA; GUPTA; MISRA, 2015; KHALID et al., 2018).

Diversos trabalhos relacionados à área, tratando do agendamento de cargas, consideram as métricas de custo e *PAPR* como fatores decisivos e centrais no processo de agendamento. Assim, quando implementados métodos de otimização, espera-se que os mesmos busquem encontrar a melhor resposta possível no menor intervalo de tempo e considerando as métricas abordadas.

A seguir descreve-se os principais trabalhos referentes ao tema bem como a sua abordagem.

Em Assaf et al. (2018), os autores propõem um programas de Gerenciamento Autônomo de Demanda (ADSM) que tem a capacidade de reduzir o custo de energia e a relação entre o pico e a média do perfil de carga através da programação do perfil de consumo de energia no dia seguinte. Neste trabalho, é investigado um programa ADSM em grupo, no qual os clientes cooperam para reduzir o custo total de geração de energia. Destaca-se ainda que os clientes são cobrados de acordo com seu próprio consumo de energia e

comprometimento com os cronogramas atribuídos. A modelagem leva em consideração os períodos prioritários que o cliente deseja agendar as suas cargas, sendo que todas cargas devem ser agendadas. Utilizou-se como método solução a “Busca Tabu”, junto com programação inteira mista não linear para modelagem das restrições. Neste trabalho foi considerado modelo tarifário do tipo *Time-Of-Use*.

Em Siebert et al. (2012), os autores propõem um método para o agendamento de consumo de dispositivos que busca auxiliar clientes residenciais a alterarem os seus hábitos. Considera a tarifa branca como tarifa do tipo *Time-of-use*. Nesta modelagem, são considerados 3 objetivos individuais, sendo eles a minimização de custo, suavização da curva de carga e a diminuição de pico. A função objetivo global é modelada através de pesos para cada um dos objetivos individuais, utilizando combinação linear convexa. Ao utilizar pesos, tem-se a possibilidade de aplicar o agendamento de acordo com o interesse para cada um dos objetivos individuais.

Segundo Siebert et al. (2012), o objetivo de redução de custo é incentivar o cliente, enquanto que os objetivos de suavização de curva de carga e diminuição da curva de pico representam benefícios para o gerenciador da rede, porém, simultaneamente, auxiliam na viabilidade da implementação da proposta de agendamento de consumo, ao evitar que diversos dispositivos sejam agendados para o mesmo momento. Utiliza algoritmos genéticos como método de solução para o agendamento de 9 cargas ao longo do dia.

Em Khalid et al. (2018), propõem um sistema de gerenciamento de energia residencial que emprega a estratégia de gerenciamento de demanda de mudanças de carga para otimizar os padrões de consumo de energia e minimizar o custo da eletricidade e a relação entre o pico e a média, mantendo o conforto do usuário por meio da coordenação entre os eletrodomésticos. Neste método, trabalha-se considerando o agendamento para o dia seguinte e em tempo real. Como proposta de solução, elaboraram uma técnica híbrida entre forrageio bacteriano (*Bacterial foraging algorithm - BFA*) e algoritmo genético (*Genetic algorithm - GA*) para encontrar uma solução eficiente que tenha qualidades de ambas as técnicas de otimização bio-inspiradas *BFA* e *GA*.

As simulações consideradas em Khalid et al. (2018) apresentam resultados referente a três regras tarifárias: *RTP*, *ToU* e *Critical Peak Pricing (CPP)*, considerando uma casa com 9 equipamentos. Neste estudo, considera-se a utilização de uma curva objetivo fornecida pela gerenciadora do sistema de energia e utilização de pesos junto as métricas de custo e *PAPR*.

Em Javaid et al. (2017), é proposto um sistema de resposta à demanda para o agendamento de cargas em ambientes residenciais utilizando três algoritmos diferentes (otimização de enxame de partículas binárias, algoritmo genético e busca cuco). Neste trabalho, tem-se a utilização de tarifas do tipo *Time-Of-Use* considerando três tipos de residências: casas tradicionais, casas inteligentes e casas inteligentes com fontes de energia renováveis. O principal objetivo neste trabalho é a redução do preço ao cliente bem como

a redução de pico, visto que nos momentos de maior criticidade com relação ao pico de consumo, o mesmo aplica tarifas de maior valor. Neste trabalho, os autores realizaram comparações entre os métodos implementados trabalhando com o agendamento de 12 cargas.

Em Logenthiran, Srinivasan e Shun (2012), os autores propõem uma estratégia de gerenciamento do lado da demanda baseada na técnica de deslocamento de carga para *Smart Grids*, considerando um grande número de dispositivos. Consideraram-se em suas simulações de rede inteligente cargas em três áreas de serviço, uma com clientes residenciais, sendo 2604 dispositivos controláveis, outra com clientes comerciais, sendo 808 dispositivos controláveis, e a terceira com clientes industriais, sendo 108 dispositivos controláveis.

Na modelagem proposta por Logenthiran, Srinivasan e Shun (2012), considera-se a minimização da diferença entre a curva de carga e a curva objetivo. A curva objetivo é projetada pelo gerenciador da rede inteligente de acordo com o objetivo do gerenciamento do lado da demanda. Neste trabalho, considerou-se discretização horária referente às cargas e todas as cargas agendáveis podem ser agendadas a qualquer momento ao longo do período de agendamento. Um algoritmo evolutivo foi utilizado como método para a solução do agendamento de cargas.

Neste trabalho propõe-se um modelo de agendamento de carga para aplicação em ambiente residencial, a modelagem considera o custo de energia e a relação da potência de pico para a potência média. Considera-se a utilização de cargas com diferentes valores de potência, tempo de duração de funcionamento e restrições de períodos de atuação. Utiliza-se discretização horária, considerando dois tipos de tarifas variáveis. Os métodos de otimização por enxame de partículas, enxame de partículas evolutivas e *Greedy Search* são utilizados como técnicas para a solução do problema de agendamento.

2.5 ESTUDO SOBRE MÉTODOS APLICADOS AO AGENDAMENTO DE CARGAS

Em aplicações de engenharia, o processo de desenvolvimento e a tomada de decisões está presente em todo lugar. A medida que os sistemas se tornam cada vez mais complexos, a decisão deve ser abordada de maneira, rápida, racional e ideal. Segundo Talbi (2009), a tomada de decisão consiste em seguir quatro etapas sendo elas: formulação, modelagem, otimização e implementação do problema.

Na etapa de implementação para a solução de um problema, duas premissas possuem grande relevância: o tempo de execução para obter a solução e a qualidade da resposta obtida para o problema. Dependendo do tipo e da complexidade do problema, cada uma dessas premissas terá um impacto na escolha de método para a solução.

Embora o ideal seja encontrar a solução ótima, tal exigência pode exigir um tempo

computacional inviável para a aplicação desejada, prejudicando assim a tomada de decisões. Diante de tal situação nas diversas áreas do conhecimento, problemas de otimização podem ser solucionados por métodos heurísticos.

A palavra heurística tem sua origem na antiga palavra grega *heuriskein*, que significa a arte de descobrir novas estratégias (regras) para resolver problemas. Segundo Logenthiran, Srinivasan e Shun (2012), os algoritmos heurísticos apresentam-se como uma alternativa de solução quando se tem uma instância muito grande do problema ou quando há pouco tempo disponível para a resolução, pois conseguem fornecer respostas quase-ótimas de forma mais rápida e que satisfaçam a necessidade da aplicação.

Assim, quando o número de possíveis soluções a serem examinadas leva à uma explosão combinatória intratável, e considerando a ausência de uma solução analítica, torna-se importante a utilização de estratégias que busquem encontrar uma solução de forma mais rápida.

Conforme revisado na seção anterior, diversos trabalhos relacionados aplicam métodos de otimização heurística (por exemplo: *GA*, *BFA* e busca tabu) para solucionar aplicações de agendamento de RD. Neste trabalho são implementados três formas para o agendamento de cargas a seguir são descritos uma visão geral sobre os métodos implementados.

2.5.1 Método de solução única com busca local no estilo *Greedy Search*

Ao resolver problemas de otimização, as heurísticas baseadas em solução única melhoram uma solução. Este tipo de algoritmo pode ser vistos como passeios pelos vizinhos ou trajetórias de busca do problema em questão. As caminhadas (ou trajetórias) são executadas por procedimentos iterativos que passam da solução atual para outra no espaço de pesquisa.

A busca local é provavelmente o método heurístico mais antigo e mais simples, começa em uma determinada solução inicial e, a cada iteração, a heurística substitui a solução atual por um vizinho que melhora a função objetivo (TALBI, 2009).

Um das formas de seleção de um vizinho melhor consiste na estratégia de escolher o primeiro vizinho que melhore a solução atual. Ao adotar o primeiro vizinho que melhore a solução, pode-se utilizar o termo *Greedy* (ganancioso), que consiste em fazer a escolha ideal localmente em cada estágio, com a intenção de encontrar um ótimo global.

Nesse tipo de algoritmos, a busca de solução começa com uma solução inicial e construímos uma solução atribuindo valores a uma variável de decisão de cada vez, até que uma solução considerada quase-ótima seja encontrada ou que um tempo limite seja decorrido.

Em muitos problemas, uma estratégia *Greedy* (gananciosa) geralmente não produz

uma solução ideal, mas, mesmo assim, pode produzir, em um período de tempo razoável, soluções localmente ótimas que se aproximam de uma solução globalmente ótima. Esses algoritmos têm em geral uma complexidade reduzida em comparação com algoritmos iterativos.

2.5.2 Método de otimização por Enxame de Partículas (*Particle Swarm Optimization - PSO*)

A Otimização por Enxame de Partículas (*Particle Swarm Optimization - PSO*) é um ramo da inteligência artificial, da área de otimização inspirada na natureza, que se baseia no comportamento social de grupos de indivíduos. Desenvolvida por Eberhart e Kennedy (1995), a técnica foi inspirada pelo comportamento social de um bando de pássaros ou cardume de peixes.

Um enxame é semelhante a uma população, enquanto uma partícula é semelhante a um indivíduo. Em termos simples, as partículas são “transportadas” através de um espaço de pesquisa multidimensional, onde a posição de cada partícula é ajustada de acordo com sua própria experiência e a de seus vizinhos (ENGELBRECHT, 2007).

Um bando de pássaros, ao realizar a revoada em busca de alimentos, e a forma espacial como o bando se distribui na tentativa de encontrá-los, pode ser considerado um método de otimização. O termo partículas representa os pássaros como indivíduos, sendo que cada um destes podem ser a possível solução para o problema. O espaço por onde estas partículas encontram-se distribuídas é o local de busca para a melhor solução do problema de otimização.

Para que seja possível que os pássaros aproximem-se do objetivo de encontrar alimentos, utiliza-se a função de aptidão que irá avaliar o desempenho de cada uma das partículas (pássaros) para alcançar o alvo. Este comportamento social e cooperativo entre as partículas possibilita que seja encontrado o objetivo (CARVALHO, 2014).

Utilizando a informação coletada no processo de busca, as partículas buscam a melhor posição encontrada por si mesma e a melhor posição de seus vizinhos para se posicionar em direção a uma solução ótima. O efeito é que as partículas “voam” em direção a um nível ideal, enquanto ainda pesquisam uma ampla área em torno da melhor solução atual. Uma das grandes vantagens do *PSO* é que o mesmo pode convergir para a solução ideal em muitos problemas onde a maioria dos métodos analíticos não converge, podendo assim, ser efetivamente aplicado a diferentes problemas de otimização (ENGELBRECHT, 2007).

Os indivíduos em um enxame de partículas seguem o comportamento de imitar o sucesso dos indivíduos vizinhos e seus próprios sucessos. O comportamento coletivo que emerge desse comportamento simples é o de descobrir regiões ótimas de um espaço de

pesquisa de alta dimensão (TALBI, 2009).

O desempenho de cada partícula é medido de acordo com uma função de adequação pré-definida, a qual está relacionada ao problema que está sendo resolvido. O algoritmo tem sido aplicado com sucesso em diversas áreas, tais como: otimização de funções, treinamento de redes neurais artificiais, controle de sistemas nebulosos e outras áreas.

No modelo básico, um enxame consiste em partículas voando em um espaço de pesquisa bidimensional. A busca se dá através da aceleração e desaceleração das partículas que são influenciadas por um componente Cognitivo (experiência da própria partícula) e um componente Social (influência do grupo).

Cada partícula i é uma solução candidata ao problema na dimensão j e é representada pela posição $x_{i,j}$ no espaço de decisão. Uma partícula tem sua própria posição ($x_{i,j}$) e velocidade ($v_{i,j}$), o que significa a direção do vôo e o passo da partícula.

As partículas voam através do problema com determinadas velocidades. A cada iteração, as velocidades das partículas individuais são ajustadas de acordo com a melhor posição histórica para a partícula em si, $pbest$ (cognitivo), e a melhor posição da vizinhança, $gbest$ (social). Tanto a partícula melhor como a vizinhança melhor são derivadas de acordo com uma função de aptidão definida pelo usuário (VALLE et al., 2008).

A população com as partículas é inicializada de forma aleatória. Cada uma das partículas é candidata a possível solução do problema e move-se pelo hiperespaço de busca. A posição de cada partícula é determinada pelo vetor $x_{i,j} \in \mathbb{R}^n$ e seu movimento pela velocidade da partícula $v_{i,j} \in \mathbb{R}^n$. Assim, baseado na posição de cada uma das partículas, determina-se a velocidade da mesma para a próxima iteração:

$$v_{i,j}^{(t+1)} = v_{i,j}^{(t)} + c_1.r_1(x_{pbest,j}^{(t)} - x_{i,j}^{(t)}) + c_2.r_2(x_{gbest,j}^{(t)} - x_{i,j}^{(t)}), \quad (2.1)$$

na qual $v_{i,j}^{(t)}$ é a velocidade da partícula i na dimensão $j = 1, \dots, n_x$ (n_x número máximo de dimensões da partícula) no instante de tempo t , c_1 e c_2 são constantes de aceleração para controlar a influência da informação cognitiva e social, respectivamente, e r_1 e r_2 são números randômicos reais entre 0 e 1 com distribuição uniforme. O índice $pbest$ é a melhor posição de cada partícula até a iteração atual e $gbest$ a melhor posição entre todas as partículas do enxame.

Baseada na velocidade a posição de cada uma das partículas é atualizada da seguinte forma:

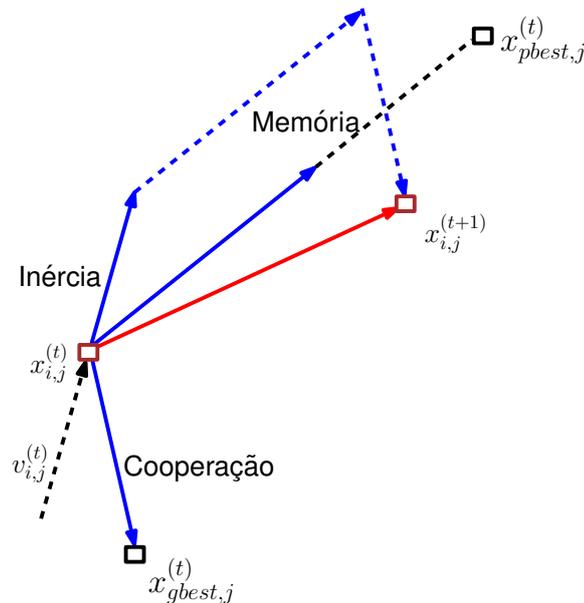
$$x_{i,j}^{(t+1)} = x_{i,j}^{(t)} + v_{i,j}^{(t+1)}, \quad (2.2)$$

sendo $x_{i,j}^{(t+1)}$ a nova posição da partícula, $x_{i,j}^{(t)}$ a posição atual da partícula e $v_{i,j}^{(t+1)}$ a velocidade de deslocamento da partícula determinada na Equação (2.1).

O efeito da equação da velocidade pode ser ilustrado em um espaço vetorial bidi-

mensional, utilizando uma representação geométrica conforme a Figura 2.7. Através dessa representação, percebe-se a influência dos componentes social, cognitivo e velocidade na busca de novas soluções no algoritmo de busca.

Figura 2.7 – Interpretação geométrica do PSO



Fonte: Adaptado de Miranda e Fonseca (2002b)

As atualizações de velocidade na Equação (2.1) consistem em três termos que contribuem movimento das partículas. Entretanto, quando as partículas encontram-se muito distantes, resulta em partículas que saem dos limites do espaço de pesquisa, assim divergindo. Para controlar a exploração global de partículas, as velocidades são fixadas para permanecer dentro de limites, se a velocidade de uma partícula exceder uma velocidade máxima especificada, a velocidade da partícula é definida para a velocidade máxima (EBERHART; SIMPSON; DOBBINS, 1996).

A velocidade das partículas é então ajustada antes da atualização da posição através da seguinte consideração:

$$v_{i,j}^{(t)} = \begin{cases} v_{i,j}'^{(t+1)} & \text{se } v_{i,j}'^{(t+1)} < V_{max,j}, \\ V_{max,j} & \text{se } v_{i,j}'^{(t+1)} \geq V_{max,j}. \end{cases} \quad (2.3)$$

Com o desejo de controlar melhor a exploração global e ajustes de velocidade, Shi e Eberhart (1998) propuseram um parâmetro denominado inércia w . O peso da inércia atua como um mecanismo para controlar as habilidades de exploração do enxame e como mecanismo para eliminar a necessidade de fixação de velocidade. A determinação adequada do valor de w proporciona um equilíbrio entre a exploração global e local, e resulta em uma quantidade de iterações menores para encontrar uma boa solução.

Assim, a velocidade passa a ser ajustada dinamicamente de acordo com suas expe-

riências e das demais soluções candidatas, e Equação (2.1) passa a ter a seguinte forma:

$$v_{i,j}^{(t+1)} = w \cdot v_{i,j}^{(t)} + c_1 \cdot r_1 (x_{pbest,j}^{(t)} - x_{i,j}^{(t)}) + c_2 \cdot r_2 (x_{gbest,j}^{(t)} - x_{i,j}^{(t)}) \quad (2.4)$$

na qual w é coeficiente de inércia, sendo as demais variáveis conforme descrito em (2.1). O valor de w é extremamente importante para garantir um comportamento convergente e otimizar as habilidades de exploração. A ideia da utilização da inércia é inicialmente buscar uma região ampla e, com o avançar das iterações, este valor vai reduzindo gradativamente, possibilitando que as partículas encontrem a solução de forma mais rápida. A determinação adequada do valor de w proporciona um equilíbrio entre a exploração global e local. Quanto menor w , mais os componentes cognitivos e sociais controlam as atualizações de posição (ENGELBRECHT, 2007).

O valor ideal para o peso da inércia é dependente do problema. Com relação a utilização de inércia, pode-se considerar uma variação linear da mesma com um valor inicial de 0.9 e final de 0.4, conforme a Equação (2.5) (SHI; EBERHART, 1998) (RATNAWEERA, 2002):

$$w_i = (w_{inicial} - w_{final}) \frac{N_{ite} - i}{N_{ite}} + w_{final} \quad (2.5)$$

em que $w_{inicial}$ e w_{final} são os valores inicial e final de inércia, respectivamente, N_{ite} é o número total de iterações e i é a iteração atual.

Outras estratégias podem ser utilizadas na tentativa de ajuste de inércia, como a adotado por Chatterjee e Siarry (2006), que pretende melhorar a velocidade de convergência do algoritmo e refinar a busca no espaço utilizando uma diminuição não-linear, em que um valor inicialmente grande diminui de maneira não-linear para um valor pequeno:

$$w_i = \left[\frac{(N_{ite} - i)^q}{N_{ite}^q} \right] (w_{inicial} - w_{final}) + w_{final}. \quad (2.6)$$

Complementando o proposto com relação ao ajuste de inércia, Ratnaweera, Halgamage e Watson (2004) propôs a constante de aceleração (c_1 e c_2) através de uma redução linear conforme a seguintes equações:

$$c_1 = (c_{1final} - c_{1inicial}) \frac{i}{N_{ite}} + c_{1final} \quad (2.7a)$$

$$c_2 = (c_{2final} - c_{2inicial}) \frac{i}{N_{ite}} + c_{2final} \quad (2.7b)$$

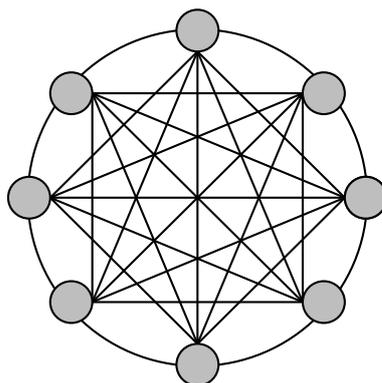
nas quais $c_{1inicial}$ e c_{1final} são constantes que controlam a influência cognitiva inicial e final respectivamente, $c_{2inicial}$ e c_{2final} são contantes que controlam a influência social inicial e final respectivamente.

Um fator importante no *PSO* refere-se à topologia de comunicação utilizada pelas partículas. A determinação da topologia representa como as partículas trocam as informações, influenciando na avaliação da velocidade das partículas. Diferentes estruturas de

redes sociais foram desenvolvidas para o *PSO* e estudadas empiricamente, sendo elas: estrela, anel, Von Neumann, árvore, roda, grafos.(ENGELBRECHT, 2007).

A Figura 2.8 apresenta a topologia estrela, onde todas as partículas estão interconectadas. Cada partícula pode, portanto, se comunicar com qualquer outra partícula. Nesse caso, cada partícula é atraída para a melhor solução encontrada por todo o enxame (CARVALHO, 2014).

Figura 2.8 – Topologia estrela aplicada ao *PSO*



Fonte: Elaborada pelo autor

2.5.3 Método de otimização por Enxame de partículas evolutivas (*Evolutionary Particle Swarm Optimization - EPSO*)

O método de otimização por partículas evolutivas (*EPSO*) é um método proposto por Miranda e Fonseca (2002b), com característica de uso geral e cujas raízes estão nas estratégias de evolução (*ES*) e nos conceitos de *PSO*.

Do ponto de vista conceitual, o *EPSO* tem uma característica que permite uma dupla interpretação de como funciona, pois pode ser visto de duas perspectivas, como uma variante do *PSO* ou como uma variante do *ES* (JAIN et al., 2007).

Entretanto, segundo Miranda e Fonseca (2002b), o *EPSO* deve ser definido com um algoritmo evolutivo auto-adaptativo, onde substituímos a recombinação da operação utilizada nos métodos evolutivos por uma nova operação chamada movimento de partículas descrita no *PSO*. Esse movimento de partículas utilizado para recombinação mostra-se mais eficaz do que a recombinação utilizada em algoritmos evolutivos.

O *EPSO* apresenta características robustas e auto-adaptativas, sendo esta uma característica positiva, visto que uma das grandes dificuldades ao utilizar o *PSO* é a quantidade de parâmetros iniciais, muitas vezes definidos de forma empírica e que apresentam alta sensibilidade.

Com relação às estratégias de evolução, uma determinada iteração pode ser cha-

mada de geração, na qual apresenta um conjunto de indivíduos, sendo que cada um desses indivíduos é caracterizado por parâmetros de objeto (os valores das variáveis, descrevendo uma solução), e por parâmetros estratégicos (taxas de mutação para cada variável, ângulos de correlação de mutação e similares). Sabe-se que cada um dos indivíduos na população corresponde a uma solução candidata ao problema (MIRANDA; FONSECA, 2002a).

Ao utilizar o *EPSO*, a ideia é conceder um esquema *PSO* com um procedimento de seleção explícito e com propriedades de auto-adaptação para seus parâmetros. As variáveis são divididas em parâmetros de objeto (as variáveis x) e parâmetros estratégicos (os pesos w). Assim, pode-se dizer que uma partícula é um conjunto de objetos e parâmetros estratégicos $[x, w]$.

Segundo Miranda e Fonseca (2002b), o regime geral do *EPSO* pode ser descrito da seguinte forma:

- **REPLICAÇÃO:** cada partícula é replicada r vezes.
- **MUTAÇÃO:** cada partícula tem seu peso alterado. Sendo que a mutação de um parâmetro w em w^* é dada de maneira aditiva através de números aleatórios os quais seguem distribuição Gaussiana (Normal), conforme a seguinte equação:

$$w_i^* = w_i + \sigma \mathcal{N}(0, 1) \quad (2.8)$$

O fato dos pesos estarem sujeitos a mutações pode dar uma chance extra para o enxame escapar dos mínimos locais (ou seja, ter partículas que ainda exploram outras regiões do espaço, porque podem ganhar velocidade suficiente) (JAIN et al., 2007).

- **REPRODUÇÃO:** cada partícula mutada gera uma prole de acordo com a regra do movimento de partículas utilizadas no *PSO*:

$$x_{i,j}^{(t+1)} = x_{i,j}^{(t)} + v_{i,j}^{(t+1)} \quad (2.9)$$

$$v_{i,j}^{(t+1)} = w_{i1}^* \cdot v_{i,j}^{(t)} + w_{i2}^* (b_{i,j}^{(t)} - x_{i,j}^{(t)}) + w_{i3}^* (b_{g,j}^{*(t)} - x_{i,j}^{(t)}) \quad (2.10)$$

sendo $b_{i,j}$ o melhor ponto encontrado pela partícula i em sua vida passada até a geração atual, $b_{g,j}$ o melhor ponto geral encontrado pelo enxame de partículas em sua vida passada até a geração atual, $x_{i,j}^{(k)}$ a localização da partícula i de dimensão j na geração k , $v_{i,j}^{(k+1)}$ a velocidade da partícula i de dimensão j na geração k , w_{i1}^* o condicionamento de peso do termo de inércia, w_{i2}^* o condicionamento de peso do termo de memória e w_{i3}^* o condicionamento de peso do termo de cooperação ou troca de informações.

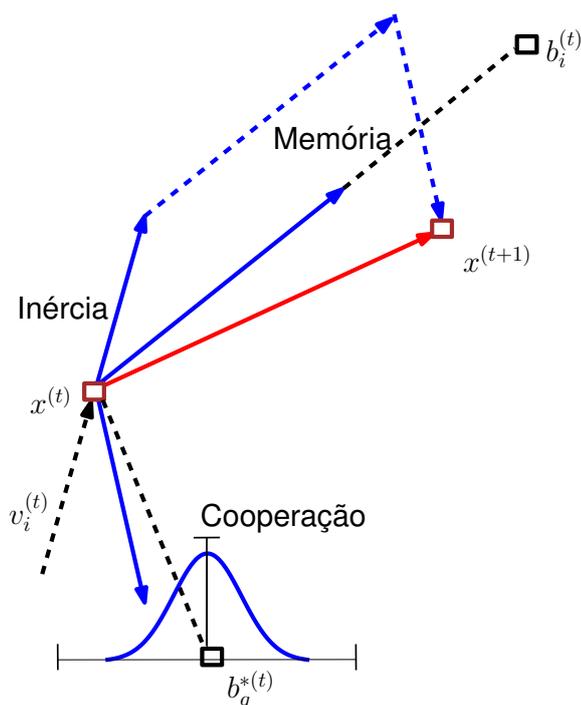
O símbolo * superscrito nas variáveis representa que a mesma sofrerá mutação e assim não apenas os pesos que afetam os componentes do movimento são alterados, mas também a melhor $b_{g,j}$ global é aleatoriamente perturbada para fornecer

$$b_{g,j}^* = b_{g,j} + \sigma \mathcal{N}(0, 1). \quad (2.11)$$

A lógica por trás dessa alteração é que se o melhor global atual já é o ideal global, isso é irrelevante; entretanto se o ideal ainda não foi encontrado, ele ainda pode estar na vizinhança, e assim torna-se importante apontar exatamente para o melhor global atual, principalmente quando a pesquisa já está focada em uma determinada região.

A Figura 2.9 apresenta a regra do movimento *EPSO*. Destaca-se que a posição das novas gerações é constituída por 3 componentes: uma inércia, por memória e cooperação. O vetor associado ao fator de cooperação não aponta exatamente para o valor ótimo global de b_g , mas para um local mutado.

Figura 2.9 – Ilustração da regra do movimento *EPSO*



Fonte: Adaptado de Jain et al. (2007)

Após a etapa de reprodução de partículas tem-se as seguintes etapas para avaliação e seleção.

- **AValiação:** Conforme a prole gerada, cada um dos filhos gerados tem sua aptidão avaliada.
- **Seleção:** um torneio estocástico é realizado, e como resultado, as melhores partículas (sobreviventes) formam uma nova geração. A seleção favorece indivíduos mais

bem adaptados (ou seja, com melhor *fitness*).

O esquema proposto neste método se beneficia de dois aspectos: o processo darwinista de seleção e a regra do movimento de partículas; portanto, é natural esperar que ele possa exibir propriedades de convergência vantajosas quando comparado apenas ao *ES* ou *PSO*.

2.6 RESUMO DO CAPÍTULO

Neste capítulo é apresentada a revisão bibliográfica referente ao tema deste trabalho. É apresentado as definições referentes a técnicas de gerenciamento pelo lado da demanda, os conceitos e importância das *Smart Grids* e *Smart Homes* para a evolução do sistema elétrico, bem como a implementação de técnicas de resposta à demanda baseada em sinais tarifários.

Ainda neste capítulo são apresentadas técnicas heurísticas utilizadas por outros trabalhos para agendamento de carga considerando as métricas de custo e PAPR. Por fim é apresentado uma revisão dos conceitos referentes ao métodos de otimização que serão implementados neste trabalho.

3 MODELAGEM DO PROBLEMA PARA UM SISTEMA DE AGENDAMENTO DE CARGAS

Neste capítulo, descreve-se a modelagem de um sistema de gerenciamento de energia residencial que emprega o mecanismo de agendamento da operação de equipamentos, baseado na técnica de deslocamento carga. Considera-se como premissa a utilização de medidor inteligente junto às unidades consumidoras, baseado em sinais tarifários para o deslocamento da carga no dia seguinte, buscando otimizar os padrões de consumo de energia.

Os objetivos são gerenciar o consumo de determinadas cargas de maneira eficiente para minimizar o custo da eletricidade e controlar a PAPR. O conforto do usuário também será levado em consideração através de restrição de intervalos horários para o agendamento dos equipamentos.

A fim de alcançar o cronograma de carga diária balanceado, utiliza-se um método de combinação linear convexa que relaciona a métrica de custo e a métrica de PAPR.

No decorrer deste capítulo, modela-se o problema em função das duas métricas consideradas, descrevendo as estratégias e as considerações utilizadas para a implementação dos algoritmos descritos no próximo capítulo.

3.1 MÉTRICAS ABORDADAS NA MODELAGEM

Para a modelagem das métricas, considere a duração de um dia discretizada uniformemente em M intervalos de tempo. Considere também uma unidade consumidora que possui N equipamentos. Cada equipamento deve ser agendados para operar uma única vez ao longo do dia, sendo que o i -ésimo equipamento deve operar durante L_i intervalos de tempo consecutivos a partir do seu instante inicial de operação $n_{1,(i)}$.

Baseado nessas considerações, deseja-se realizar o agendamento de operação desses equipamentos de forma que seja possível otimizar algumas métricas do sistema.

3.1.1 Custo de energia ao longo de um período

A função custo está relacionada diretamente ao consumidor que poderá participar efetivamente do processo e receber benefícios em troca. Embora essa métrica possa representar perda de ganho de receitas para a empresa distribuidora ela torna-se como um atrativo para os clientes participem e possibilitem que suas cargas sejam deslocadas.

Considera-se que o preço de eletricidade pode apresentar variações ao longo de períodos, de acordo com programas de resposta a demanda baseado em preços.

Essa métrica está relacionada diretamente ao número de equipamentos que podem participar da programação, dos diferentes valores de potência que os equipamentos podem apresentar, do tempo que podem permanecer ligados e ao custo tarifário, variável ao longo do dia. Sendo assim podemos definir o custo da energia ao longo de um período como uma função f_1 , dada por:

$$f_1 = \sum_{i=1}^N \sum_{m=0}^{M-1} P_i U_{i,m} C_m, \quad (3.1)$$

na qual P_i é a potência do i -ésimo equipamento (para $i = 1, \dots, N$), $U_{i,m}$ é um valor binário que representa o estado de operação para o i -ésimo equipamento durante o m -ésimo instante de tempo (para $m = 0, \dots, M - 1$), e C_m representa o valor da tarifa do m -ésimo intervalo de tempo.

A Equação (3.1) pode ser expressa na forma matricial, dada por

$$f_1 = \mathbf{P} \times \mathbf{U} \times \mathbf{C}, \quad (3.2)$$

na qual:

$\mathbf{P} \in \mathbb{R}^N$: é um vetor linha $1 \times N$ que concatena a potência de todos equipamentos e pode ser expresso da seguinte forma: $\mathbf{P} = [P_1 \ \dots \ P_N]_{1 \times N}$;

$\mathbf{C} \in \mathbb{R}^M$: é um vetor coluna $M \times 1$, cujas entradas representam o custo da energia para cada intervalo de tempo, e pode ser expresso da seguinte forma: $\mathbf{C} = [C_0 \ \dots \ C_{M-1}]_{M \times 1}^T$;

$\mathbf{U} \in \mathbb{R}^{N \times M}$: é uma matriz binária que representa os intervalos em que cada equipamento permanece ligado ou desligado. As entradas $U_{n,m}$ podem assumir valor 1 para indicar que o equipamento n está em operação durante o instante de tempo m , ou o valor 0 caso o equipamento esteja desligado nesse instante, semelhante a modelagem proposta por Assaf et al. (2018);

Destaca-se que cada equipamento poderá ter a sua característica e permanecer ligado por uma sequência longa e contígua de intervalos. A quantidade de intervalos em sequência que o equipamento pode permanecer ligado é representado pela variável L_i , enquanto $m_{1,(n)}$ representa o instante inicial de operação de cada equipamento, conforme ilustrado na notação abaixo:

$$\mathbf{U} = \begin{bmatrix} 0 & \dots & 1 & \dots & 1 & 0 \\ & & m=m_{1,(1)} & \times L_1-2 & m=m_{1,(1)}+L_1 & \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \dots & 1 & \dots & 1 & 0 \\ & & m=m_{1,(N)} & \times L_N-2 & m=m_{1,(N)}+L_N & \end{bmatrix}_{N \times M}.$$

3.1.2 Razão da potência de pico para a potência média

A métrica da PAPR ao longo do dia busca garantir controle e a redução de carregamento sobre a rede de distribuição (KHALID et al., 2018).

Essa função representa benefício para a empresa fornecedora de energia quando do gerenciamento pelo lado da demanda, auxiliando na viabilidade da implementação da proposta de agendamento de consumo.

Ao evitar que diversos dispositivos sejam agendados para o mesmo momento, ela busca garantir a estabilidade da rede, evitando assim que uma grande quantidade de cargas sejam agendadas para um único intervalo de tempo m .

Segundo Siebert et al. (2012), podemos descrever matematicamente a PAPR como uma função f_2 dada por:

$$f_2 = \frac{P_{\max}}{P_{\text{avg}}} \quad (3.3)$$

na qual P_{\max} é o valor máximo de potência dentre todos os M intervalos de tempo possíveis de agendamento e P_{avg} é média de potência longo do período M considerando os equipamentos a serem agendados. As expressões para P_{\max} e P_{avg} são definidas, respectivamente, nas Equações (3.4) e (3.5):

$$P_{\max} = \max_m \sum_{i=1}^N P_i U_{i,m}, \quad (3.4)$$

$$P_{\text{avg}} = \frac{1}{M} \sum_{m=0}^{M-1} \sum_{i=1}^N P_i U_{i,m}. \quad (3.5)$$

3.2 CUSTO E PAPR ATRAVÉS DE COMBINAÇÃO LINEAR CONVEXA

A combinação linear é uma expressão construída a partir da soma ponderada dos elementos de um conjunto de termos. Sendo assim, seja $S = \{f_1, f_2, \dots, f_n\}$ um conjunto de vetores de um espaço vetorial linear. As combinações lineares de S são formadas da seguinte forma:

$$a_1 \times f_1 + a_2 \times f_2 \cdots a_n \times f_n \quad (3.6)$$

sendo a_1, a_2, \dots, a_n números reais que podem ser chamados de coeficientes da combinação linear.

Se os coeficientes da combinação $a_1, \dots, a_n \in \mathbb{R}$ são tais que $a_i \geq 0$ ($i = 1, 2 \dots n$)

e obedecem o descrito na Equação (3.7),

$$\sum_{i=1}^n a_i = 1, \quad (3.7)$$

então a combinação linear é chamada combinação convexa dos elementos $\{x_1, x_2, \dots, x_n\}$.

Assim, para um conjunto $S = \{f_1, \dots, f_n\}$, a expressão de uma combinação linear convexa é dada por:

$$F_{obj} = \sum_{j=1}^n a_j f_j. \quad (3.8)$$

O modelo da Equação (3.8) contempla a combinação linear convexa das métricas f_1 e f_2 como métrica para a proposta de agendamento do consumo. Considere z_1 e z_2 como sendo os coeficientes de combinação linear para as funções (3.2) e (3.3), respectivamente. Tem-se então a expressão:

$$F_{obj} = z_1 \times f_1 + z_2 \times f_2 \quad (3.9)$$

Como a combinação linear é convexa neste modelo, obedecendo assim o descrito em (3.7), tem-se que:

$$z_1 + z_2 = 1 \quad (3.10)$$

Seja $z_1 = z$ logo podemos escrever (3.8) em torno de somente um escalar.

$$F_{obj} = z \times f_1 + (1 - z) \times f_2 \quad (3.11)$$

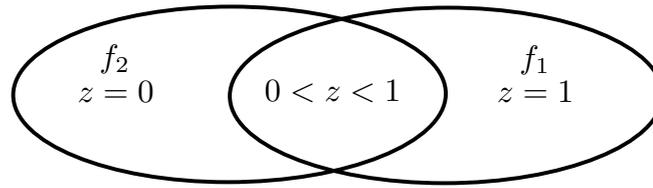
na qual z e $1 - z$ são os pesos considerados para cada uma das métricas abordadas, sendo que $0 \leq z \leq 1$. Ao restringir o valor de z entre 0 e 1 na equação (3.11), garante-se que os coeficientes da combinação linear das duas métricas sempre obedecem (3.7).

De forma explícita, o sistema proposto com as métricas descritas e a combinação linear convexa é dado por:

$$F_{obj} = z \times (\mathbf{P} \times \mathbf{U} \times \mathbf{C}) + (1 - z) \times \frac{P_{\max}}{P_{\text{avg}}} \quad (3.12)$$

Observe que, ao utilizar $z = 1$, a modelagem só considerará a métrica f_1 referente ao custo para o cliente, enquanto que, ao utilizar $z = 0$, a função considerada será apenas f_2 , dando ênfase no desempenho relacionado a operadora de energia. Qualquer outro valor entre 0 e 1 levará em consideração as duas funções envolvidas na modelagem proposta, conforme ilustrado na Figura 3.1.

Figura 3.1 – Importância do peso adotado para as métricas consideradas



Fonte: Elaborado pelo autor

3.3 MATRIZ DE AGENDAMENTO DE CARGA \mathbf{U}

Neste modelo a matriz de agendamento de carga \mathbf{U} apresenta papel um decisivo e que influência diretamente no valores obtidos nas métricas. Através de \mathbf{U} , tem-se os períodos de funcionamento dos equipamentos e através da sua manipulação torna-se possível obter os resultados de agendamento ao longo do dia.

A matriz descrita em (3.13) mostra um exemplo de valor possível para a variável \mathbf{U} em um cenário particular. Neste caso, a matriz apresenta $N = 4$ linhas (equipamentos) e $M = 10$ colunas (intervalos de tempo), sendo que, na condição inicial, todos os equipamentos são colocados na primeira posição permitida para o seu funcionamento.

$$\mathbf{U} = \begin{bmatrix} 0 & 0 & 0 & 0 & \mathbf{1} & 0 & 0 & 0 & 0 & 0 \\ \mathbf{1} & \mathbf{1} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \mathbf{1} & \mathbf{1} & \mathbf{1} & 0 & 0 & 0 & 0 & 0 & 0 \\ \mathbf{1} & \mathbf{1} & \mathbf{1} & \mathbf{1} & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}_{4 \times 10} \quad (3.13)$$

No exemplo apresentado, a quantidade de intervalos em sequência que cada equipamento pode permanecer ligado, L_i , pode ser extraída da matriz. Este intervalo é variável de acordo com a característica de cada um dos equipamentos (linhas). Considerando o exemplo em (3.13), e concatenando os valores de L_i em um vetor, tem-se:

$$\mathbf{L} = \begin{bmatrix} 1 & 2 & 3 & 4 \end{bmatrix}_{1 \times 4}^T \quad (3.14)$$

Destaca-se que cada equipamento pode apresentar colunas (intervalos de tempo) como regiões proibidas que não seja possível permanecer no estado de operação ligado. Essa ação de restrição de determinados períodos busca contribuir para que seja considerado um grau de conforto ao usuário. (KHALID et al., 2018).

Manipulando a matriz \mathbf{U} , torna-se possível buscar o agendamento desejado, através de deslocamentos circulares de suas linhas e considerando os intervalos permitidos. Destaca-se que nestes deslocamentos deve-se manter a mesma sequência de estado de operação, conforme pode ser visto na matriz de exemplo.

Após deslocamentos arbitrários, geramos um novo exemplo de agendamento, re-

presentado pela matriz denominada de \mathbf{U}_{temp} :

$$\mathbf{U}_{temp} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \mathbf{1} & 0 \\ 0 & 0 & 0 & 0 & \mathbf{1} & \mathbf{1} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \mathbf{1} & \mathbf{1} & \mathbf{1} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \mathbf{1} & \mathbf{1} & \mathbf{1} & \mathbf{1} & 0 \end{bmatrix}_{4 \times 10}. \quad (3.15)$$

3.3.1 Transformação da matriz de agendamento de carga em um vetor

A matriz \mathbf{U} apresenta, para cada uma das suas linhas, um estado de operação que pode ser descrito através de um número binário. Sendo assim, uma forma alternativa de representar essa matriz é transformar cada uma das suas linhas em um número inteiro, usando uma conversão de uma sequência binária para sua representação decimal.

Seja $\mathbf{u}_i \in \mathbb{F}_2^M$ a i -ésima linha da matriz \mathbf{U} , vista como um número binário de M bits, onde o seu bit mais significativo (MSB) é $U_{i,1}$. O mapeamento entre essa sequência binária e sua representação de inteiros é dado pela função $\mu : \mathbb{F}_2^M \rightarrow \mathbb{Z}_{2^M}$, sendo $b_i = \mu(\mathbf{u}_i)$ o número inteiro correspondente do mapeamento.

Baseado na conversão, tem-se um vetor com número inteiro (decimal) que representa o instante de operação de cada um dos equipamentos existentes, e que pode ser definido da seguinte forma:

$$\mathbf{b} = \begin{bmatrix} b_1 & \cdots & b_N \end{bmatrix}_{1 \times N}^T. \quad (3.16)$$

Assim cada linha em binário de \mathbf{U} que representa intervalos do equipamento ligado pode ser convertido para um número decimal. Para o exemplo da matriz \mathbf{U} em (3.13), a conversão de cada linha, para um número inteiro pode ser expressa da seguinte forma:

$$\mathbf{b} = \mu(\mathbf{U}) = \begin{bmatrix} 32 & 768 & 448 & 960 \end{bmatrix}_{1 \times 4}^T \quad (3.17)$$

Considerando o número binário como origem do número decimal, baseado no MSB em $U_{i,1}$, e sabendo que todos os equipamentos são colocados na primeira posição permitida para o seu funcionamento, pode-se expressar o deslocamento circular da seguinte maneira:

$$b'_i = b_i \times 2^{-E_i}, \quad (3.18)$$

sendo E_i o passo de deslocamento do i -ésimo equipamento, referenciado ao número binário, sendo que a variação na posição do agendamento pode ser representada por um novo número inteiro b'_i .

O deslocamento realizado dentro dos intervalos permitidos de operação dos dispo-

sitivos, de acordo (3.18), pode ser representado utilizando o produto de Hadamard:

$$\mathbf{b}' = \mathbf{b} \odot \mathbf{s} \quad (3.19)$$

na qual:

\mathbf{b}' : é vetor das posições de cada um dos equipamentos após o deslocamento;

\mathbf{b} : é a posição antes do deslocamento conforme descrito em (3.16), sendo que a mesma pode ser referenciada a qualquer momento do intervalo permitido, de acordo com a condição desejada no algoritmo proposto (no exemplo anterior, tinham-se todos os equipamentos colocados na primeira posição permitida);

\mathbf{s} : representa o deslocamento da carga em relação a sua posição de referência, baseado no MSB em $U_{i,1}$.

Sendo assim, tem-se que:

$$\mathbf{b}' = \begin{bmatrix} b_1 & \dots & b_N \end{bmatrix}_{1 \times N}^T \odot \begin{bmatrix} 2^{-E_1} & \dots & 2^{-E_N} \end{bmatrix}_{1 \times N}^T. \quad (3.20)$$

Destaca-se que o produto de Hadamard é uma operação binária que toma duas matrizes de mesmas dimensões e produz outra matriz da mesma dimensão, na qual cada elemento i, j resultante é o produto dos elementos i, j das duas matrizes originais.

Percebe-se através da modelagem utilizada que a variável E_i apresenta papel importante, pois através de sua manipulação torna-se possível encontrar o melhor agendamento para as cargas. Podemos definir \mathbf{E} como sendo um vetor que concatena todos os expoentes E_i :

$$\mathbf{E} = \begin{bmatrix} E_1 & \dots & E_N \end{bmatrix}_{1 \times N}. \quad (3.21)$$

Outro fator importante é a possibilidade de considerar restrições de operação a cada uma das cargas aplicando restrições a este expoente. Sendo assim, introduz-se E_i^{max} para representar o máximo de deslocamento que a carga i pode realizar em relação a referência de posição aplicada. Através dessas considerações torna-se possível trabalhar com as restrições de períodos de funcionamento de cada uma das cargas envolvidas, conforme o descrito pela definição:

$$E_i \in \mathbb{Z}_{E_i^{max}+1} \quad (3.22)$$

para que E_i varie de $0, \dots, E_i^{max}$.

O exemplo de deslocamento considerado em (3.15), baseado na condição inicial descrita em (3.13), pode então ser descrito da seguinte forma:

$$\mathbf{b}' = \begin{bmatrix} 32 & 768 & 448 & 960 \end{bmatrix}_{1 \times 4}^T \odot \begin{bmatrix} 2^{-4} & 2^{-4} & 2^{-3} & 2^{-5} \end{bmatrix}_{1 \times 4}^T \quad (3.23a)$$

$$= \begin{bmatrix} 2 & 48 & 56 & 30 \end{bmatrix}_{1 \times 4}^T. \quad (3.23b)$$

O resultado de \mathbf{b}' descrito em (3.23b) representa a matriz descrita em (3.15). O principal objetivo de tal transformação é facilitar a implementação dos algoritmos descritos nos próximos capítulos.

Destaca-se que para este cenário particular o vetor \mathbf{E} que concatena todos os expoentes E_i pode então ser descrito da seguinte forma:

$$\mathbf{E} = \begin{bmatrix} 4 & 4 & 3 & 5 \end{bmatrix}_{1 \times 4}. \quad (3.24)$$

3.4 PROBLEMA DE OTIMIZAÇÃO DO AGENDAMENTO DE CARGA

Considere os problemas de minimização do custo (f_1) e controle do pico máximo de demanda no período (f_2), abordados ao longo deste capítulo, e a modelagem de combinação linear (3.12).

Aliado às adaptações realizadas na matriz de agendamento de carga \mathbf{U} , que a transforma em um vetor de números decimais, percebe-se que o principal objetivo de otimização torna-se encontrar os melhores expoentes de deslocamento da variável \mathbf{E} em relação a posição inicial para cada uma das cargas.

O problema de otimização pode ser definido baseado na função objetivo (F_{obj}), descrita em (3.12), e é apresentado da seguinte forma:

$$\underset{\mathbf{E}}{\text{minimizar}} F_{obj}(\mathbf{E}^*) \quad (3.25a)$$

sujeito à

$$P_i > 0 \quad \forall i \quad (3.25b)$$

$$C_m > 0 \quad \forall m \quad (3.25c)$$

$$U_{i,m} \in \{0, 1\} \quad \forall i, m \quad (3.25d)$$

$$0 \leq \sum_{i=1}^N P_i U_{i,m} \leq P_{\max} \quad \forall m \quad (3.25e)$$

$$0 \leq m_{1,(i)}^{\min} \leq m_{1,(i)} \leq m_{1,(i)}^{\max} \leq M - L_i \quad \forall i. \quad (3.25f)$$

As técnicas e formas de solução deste problema de otimização serão descritas nos capítulos seguintes.

3.5 APLICAÇÃO DE HEURÍSTICAS VISTO O AMPLO ESPAÇO DE BUSCA PARA O AGENDAMENTO DE CARGAS

Considerando a modelagem proposta e o problema de otimização baseado nas métricas abordadas para o agendamento de N cargas, percebe-se um espaço de busca para a solução muito amplo.

Para uma solução ótima de um cenário qualquer, a realização de uma busca exaustiva comprometeria principalmente a premissa de eficiência no tempo de execução. O total de combinações possíveis, considerando deslocamentos independentes para cada equipamento bem como as suas restrições de operação, pode ser encontrado através da seguinte equação:

$$\prod_{i=1}^N (m_{1,(i)}^{\max} - m_{1,(i)}^{\min} - L_i + 2) \quad (3.26)$$

na qual $m_{1,(i)}^{\min}$ refere-se ao limite inferior de tempo que o equipamento i pode ser agendado, $m_{1,(i)}^{\max}$ refere-se ao limite superior que o equipamento i pode ser agendado e L_i é o comprimento da sequência de slots de tempo que o equipamento necessita para a sua operação.

Considerando a modelagem proposta para o agendamento de cargas, um sistema hipotético constituído por 10 cargas, sendo que todas as cargas podem ser agendadas ao longo de qualquer período dentre $M = 24$ intervalos de operação, portanto com $m_{1,(i)}^{\min} = 0$, $m_{1,(i)}^{\max} = 23$ e $L_i = 1$, o número total de possíveis combinações para este caso determinado, de acordo com (3.26), é:

$$\prod_{i=1}^{10} (23 - 0 - 1 + 2) = 6.3403 \times 10^{13}. \quad (3.27)$$

Percebe-se que avaliar 6.3403×10^{13} combinações para que se encontre a solução ótima torna-se computacionalmente inviável. Quando o número de cargas é aumentado para $N = 100$, o número de possíveis combinações para que se encontre a solução ótima é 1.0498×10^{138} , computacionalmente intratável para busca exaustiva.

As restrições dos períodos de agendamento diminuem o total de possíveis soluções conforme L_i , $m_{1,(i)}^{\min}$ crescem, mas em geral, esse resultado tende a ser intratável em uma busca exaustiva dado amplo espaço de busca necessário.

Portanto, uma das estratégias para contornar este tipo de problema, em alternativa à busca exaustiva, é a utilização de outros métodos de otimização, como técnicas heurística ou meta-heurística.

Ao projetar uma heurística, dois critérios devem ser levados em consideração: exploração do espaço de busca (diversificação) e exploração da melhor soluções encontrada (intensificação). Em geral, heurísticas baseadas em solução única são mais orientadas à intensificação, enquanto as heurísticas baseadas na população são mais orientadas à

exploração (TALBI, 2009).

Algoritmos baseados em solução única (por exemplo, pesquisa local, recozimento simulado) manipulam e transformam uma solução única durante a pesquisa, enquanto em algoritmos baseados em população (por exemplo, enxame de partículas, algoritmos evolutivos) toda uma população de soluções evolui.

A forma de busca de uma solução dos algoritmos heurísticos pode ser de duas formas: iterativos ou *Greedy*. Em algoritmos iterativos, o mesmo começa com uma população de soluções e a transforma a cada iteração usando alguns operadores de pesquisa. Os algoritmos *Greedy* começam com uma solução vazia e, a cada passo, uma variável de decisão do problema é atribuída até que uma solução completa seja obtida (TALBI, 2009).

3.6 ALGORITMOS IMPLEMENTADOS DE ACORDO COM A MODELAGEM PROPOSTA

Considerando a modelagem proposta, os algoritmos implementados buscam encontrar a melhor a solução para o agendamento de carga considerando a minimização da função objetivo descrita na Equação (3.28):

$$F_{obj} = z \times (\text{Custo}) + (1 - z) \times (\text{PAPR}) \quad (3.28)$$

para algum valor fixo do parâmetro $z \in [0, 1]$, sendo “Custo” definido em (3.2) e a PAPR definida em (3.3).

3.6.1 Algoritmo de solução única com busca local para o agendamento de carga

O algoritmo desenvolvido considera a atomicidade das tarefas, ou seja, se um dispositivo inicia seu funcionamento necessariamente ele deve continuar em funcionamento ininterruptamente até o fim de seu ciclo. Além disso, é garantido no algoritmo que todos os dispositivos serão agendados.

Considera-se neste algoritmo que cada uma das cargas é posicionada sempre no primeiro *slot* de tempo disponível para o agendamento. Sabendo que a variável \mathbf{E} representa os deslocamentos em relação a primeira posição permitida para o funcionamento de cada equipamento, o objetivo torna-se encontrar o valor de \mathbf{E} que representa o melhor agendamento para cada uma das cargas envolvidas no processo de agendamento.

Inicialmente, na primeira condição, com todas as cargas alocadas em sua primeira posição, verifica-se o valor obtido para a função objetivo (F_{obj}) referente ao agendamento.

A cada iteração, um vetor \mathbf{E} que representa os deslocamentos é gerado de forma aleatória, respeitando os intervalos permitidos para o funcionamento dos equipamentos.

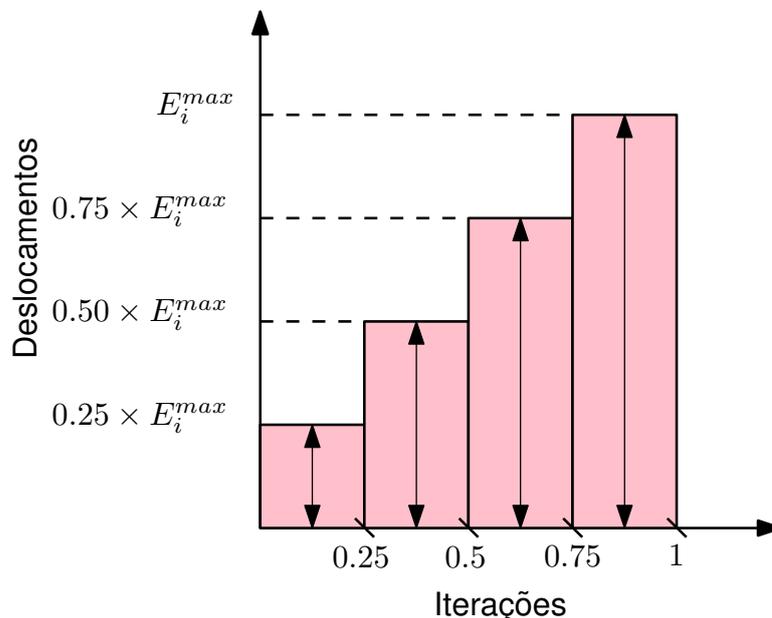
Com este novo vetor, verifica-se os novos *slots* de tempo ocupados pelas cargas e observa-se o novo valor para F' . Caso a sua nova condição tenha melhorado em relação a condição anterior, a mesma passa a ser o estado ótimo (temporário) de agendamento das cargas.

Assim, o algoritmo trabalha no estilo *Greedy Search*, sendo que faz a escolha ideal em cada etapa na tentativa de encontrar uma melhor resposta. Nesta situação, considera-se uma busca local para a solução deste problema. Uma das principais vantagens é a flexibilidade na construção e desenvolvimento que permite a implementação de recursos que levem em consideração o grau de conforto dos usuários.

Destaca-se que a busca ao longo do processo iterativo ocorre em degraus referente as vizinhanças, dividindo o processo iterativo em quatro etapas. Gera-se inicialmente o vetor com deslocamentos \mathbf{E} de tal forma que busque contemplar pequenas perturbações com relação a posição inicial, assim embora seja gerado de forma aleatória, o mesmo possui limites máximos de deslocamento que restringem para uma busca local. Entretanto, com o avançar das iterações, o vetor \mathbf{E} apresenta um certo relaxamento e ampliação no espaço de busca.

A Figura 3.2 apresenta os patamares referentes ao relaxamento dado a variável \mathbf{E} ao longo da execução do algoritmo.

Figura 3.2 – Referência utilizada para gerar o vetor de deslocamento \mathbf{E} ao longo da execução do algoritmo



Fonte: Elaborada pelo autor

O Pseudo-código é apresentado na abaixo:

Algoritmo 1 Pseudo-código do Método 01 implementado.

```

1: procedimento GREEDYSEARCH( $U^{(0)}, N_s, \mathbf{P}, \mathbf{c}, M, m_{1,(i)}^{\max}, m_{1,(i)}^{\min}, L_i, P_m$ )
2:   Inicialização: Aloca toda as cargas no primeiro slot  $M$  permitido
3:   Calcula o valor  $F_{obj}$ 
4:   para  $i = 1, \dots, N_{ite}$  faça
5:     Transforma  $U$  em  $\mathbf{b}$ 
6:     substitua a condição True faça
7:       caso  $i < 0,25 \times N_{ite}$ 
8:          $d \leftarrow$  inteiro  $\sim \mathcal{U} \left[ 0, \frac{E_i^{\max}}{4} \right]$ 
9:       caso  $0,25 \times N_{ite} \leq i < 0,50 \times N_{ite}$ 
10:         $d \leftarrow$  inteiro  $\sim \mathcal{U} \left[ \frac{E_i^{\max}}{4}, \frac{E_i^{\max}}{2} \right]$ 
11:       caso  $0,50 \times N_{ite} \leq i < 0,75 \times N_{ite}$ 
12:         $d \leftarrow$  inteiro  $\sim \mathcal{U} \left[ \frac{E_i^{\max}}{2}, \frac{3}{4} E_i^{\max} \right]$ 
13:       caso  $i \geq 0,75 \times N_{ite}$ 
14:         $d \leftarrow E_i^{\max}$ 
15:        $\mathbf{E} \leftarrow$  vetor de  $N$  inteiros cujas entradas são  $E_i \sim \mathcal{U}[-d, +d]$ 
16:       Aplica Hadamard e desloca as cargas calculando  $\mathbf{b}'$ .
17:       Retorna para a condição de matriz  $U$ 
18:       Calcula  $F'$ 
19:       se  $F' < F_{obj}$  então
20:          $F_{obj} \leftarrow F'$ 
21:       fim se
22:     fim para
23: fim procedimento

```

3.6.2 Algoritmo PSO para o agendamento de carga

Considerando o problema de otimização, o principal objetivo é encontrar a melhor partícula que satisfaça o agendamento de N cargas que otimize a função do objetivo da Equação (3.28).

Cada partícula neste modelo representa uma possível candidata para o agendamento de cargas. Para adaptar o *PSO* ao modelo do problema de agendamento, o vetor $\mathbf{E}_{i,N}$ é indexado para cada partícula i , representando as posições de agendamento da partícula i para as N cargas, conforme dado a seguir:

$$\mathbf{E}_{i,N} = \left[E_{i,1} \quad \cdots \quad E_{i,N} \right]_{1 \times N}. \quad (3.29)$$

Note que cada partícula possui N dimensões, sendo que cada dimensão da partícula é constituída por um número que representam a posição, os *slots* de agendamento de cada uma das cargas consideradas no problema de otimização.

Relacionando com a Equação (2.10), pode-se dizer que $E_{i,j}$ representa o vetor de $x_{i,j}$ das posições. Cada partícula $E_{i,j}$ representa uma possível solução e a cada iteração é verificada a *pbest* e a *gbest* que representam os estados de agendamento das cargas. O número de partículas é determinado em cada um dos cenários aplicados.

Pode-se reescrever a referida equação da seguinte forma:

$$v_{i,j}^{(t+1)} = w.v_{i,j}^{(t)} + c_1.r_1(E_{pbest,j}^{(t)} - E_{i,j}^{(t)}) + c_2.r_2(E_{gbest,j}^{(t)} - E_{i,j}^{(t)}). \quad (3.30)$$

A equação da posição de cada uma das partículas é atualizada da seguinte forma:

$$E_{i,j}^{(t+1)} = E_{i,j}^{(t)} + v_{i,j}^{(t+1)}. \quad (3.31)$$

Cada partícula $E_{i,j}$ representa uma possível solução e a cada iteração é verificada a $pbest$ (melhor solução de agendamento para cada uma das partículas) e a $gbest$ (melhor partículas de todas) que representam os estados de agendamento das cargas. O número de partículas é determinado em cada um dos cenários aplicados, considerando segundo (TALBI, 2009) que quanto mais partículas, menos iterações para alcançar uma boa solução, em comparação com enxames menores.

A seguir, tem-se a representação do pseudo-código utilizado para o algoritmo implementado neste trabalho.

Algoritmo 2 Pseudo-código do Método 02 implementado.

```

1: procedimento ALGORITMO PSO( $U^{(0)}, N_s, P, c, M, m_{1,(i)}^{\max}, m_{1,(i)}^{\min}, L_i, P_m$ )
2:   Inicializa partículas
3:   para  $i = 1, \dots, tamanhoEnxame$  faça
4:     Inicializa  $E_i$  aleatório;
5:     Inicializa  $v_i$  em 0;
6:     Inicializa  $pBest_i$ ;
7:   fim para
8:   inicializa  $gBest$ .
9:   para  $i = 1, \dots, N_{ite}$  faça
10:    para  $i = 1, \dots, tamanhoEnxame$  faça
11:      Calcula  $F_{obj}$  para a partícula  $i$ ;
12:      Atualiza  $v_i$  de acordo com (3.30);
13:      Atualiza  $E_i$  de acordo com (3.31)
14:      Calcula  $F_{objtemp}$  para a partícula  $i$ ;
15:      se  $F_{objtemp} < F_{obj}$  então
16:         $pBest_i \leftarrow E_i$ 
17:      se  $E_i < gBest$  então
18:         $gBest \leftarrow E_i$ 
19:      fim se
20:    fim se
21:  fim para
22:
23:  fim para
24:  retorna  $gBest$ 
25: fim procedimento

```

3.6.3 Algoritmo *EPSO* para o agendamento de carga

Considerando o problema de otimização, o principal objetivo é encontrar a melhor partícula que satisfaça o agendamento de N cargas considerando a função do objetivo para um dado valor de peso z .

A população neste método é constituída por um conjunto de partículas que representam uma possível candidata para a solução do agendamento de cargas.

$E_{i,N}$ é definido conforme (3.29). Cada partícula é replicada r vezes, sendo que em Miranda e Fonseca (2002b) considera r igual a 2. A mutação de um parâmetro w em w^* é dada de maneira aditiva através de números aleatórios os quais seguem distribuição Gaussiana (Normal), conforme a seguinte equação:

$$w_i^* = w_i + \sigma \mathcal{N}(0, 1). \quad (3.32)$$

As equações descritas no método *PSO* podem-se ser substituída nesta implementação através da seguinte forma:

$$E_{i,j}^{(t+1)} = E_{i,j}^{(t)} + v_{i,j}^{(t+1)} \quad (3.33)$$

$$v_{i,j}^{(t+1)} = w_{i1}^* \cdot v_{i,j}^{(t)} + w_{i2}^* (E_{i,j} - x_{i,j}) + w_{i3}^* (E_{g,j}^* - x_{i,j}) \quad (3.34)$$

A seguir, tem-se a representação do pseudo-código utilizado para o algoritmo implementado neste trabalho.

3.7 OPERAÇÕES DE ARREDONDAMENTO E CEIFAMENTO

Destaca-se que para os 3 algoritmos implementados dependendo resultado dos deslocamentos, é necessário aplicar uma função de “ceifamento” (*clipping*), que pode ser definida como $[x]_a^b = \min(b, \max(a, x))$. Assim, após calcular os valores de E_i , em qualquer caso, sempre deve ser aplicado $E_i \leftarrow [E_i]_0^{E_i^{\max}}$.

Para os métodos *PSO* e *EPSO*, sabendo que as Equações de posição (3.31) e (3.34) referem-se as valores contínuos, utilizou-se função de arredondamento para o inteiro mais próximo: $y = \lceil x \rceil$, sendo que $x \in \mathbb{R}$ e $y \in \mathbb{Z}$. Tem-se $E_i \leftarrow \lceil E_i \rceil$.

Algoritmo 3 Pseudo-código do Método 03 implementado.

```

1: procedimento ALGORITMO EPSO( $U^{(0)}, N_s, \mathbf{P}, c, M, m_{1,(\hat{i})}^{\max}, m_{1,(\hat{i})}^{\min}, L_i, P_m$ )
2:   Inicializa a população
3:   para  $i = 1, \dots, \text{tamanhoEnxame}$  faça
4:     Inicializa  $E_i$  aleatório;
5:     Inicializa  $v_i$  em 0;
6:     Inicializa  $pBest_i$ ;
7:   fim para
8:   inicializa  $gBest$ .
9:   para  $i = 1, \dots, N_{ite}$  faça
10:    Replica  $E_i$   $r$  vezes
11:    Mutação de acordo com (3.32)
12:    para  $i = 1, \dots, \text{tamanhoEnxame}$  faça
13:      Calcula  $F_{obj}$  para a partícula  $i$ ;
14:      Atualiza  $v_i$  de acordo com (3.34);
15:      Atualiza  $E_i$  de acordo com (3.33)
16:      Calcula  $F_{objtemp}$  para a partícula  $i$ ;
17:      Avaliação
18:      se  $F_{objtemp} < F_{obj}$  então
19:         $pBest_i \leftarrow E_i$ 
20:        se  $E_i < gBest$  então
21:           $gBest \leftarrow E_i$ 
22:        fim se
23:      fim se
24:    fim para
25:  fim para
26:  retorna  $gBest$ 
27: fim procedimento

```

3.8 RESUMO DO CAPÍTULO

Neste capítulo é apresentada a modelagem matemática utilizada para o problema de otimização. Inicialmente são apresentadas as definições e equações para as métricas de custo e PAPR, bem como as considerações do modelo. Após é apresentada a função objetivo através da combinação linear convexa das duas métricas em função do peso z .

Por fim, são apresentados os métodos heurísticos utilizados no agendamento de carga. São descritos 3 métodos de otimização implementados neste trabalho, bem como as considerações para os mesmos de acordo com a modelagem matemática realizada.

4 SIMULAÇÕES APLICADAS PARA VALIDAÇÃO DOS MÉTODOS IMPLEMENTADOS

Neste Capítulo, são apresentadas as simulações referentes aos métodos com deslocamentos aleatórios, *PSO* e *EPSO* descritos no Capítulo 3, considerando diversos cenários de cargas e tarifas.

4.1 CONSIDERAÇÕES GERAIS

As simulações e desenvolvimento deste trabalho foram realizadas através da utilização do software *MATLAB*.

Para as simulações considera-se a duração de um dia discretizada uniformemente em $M = 24$ intervalos de tempo. Considera-se também uma unidade consumidora que possui N cargas com características distintas e L_i intervalos de tempo consecutivos de funcionamento a partir do seu instante inicial de operação $m_{1,(i)}$.

Os casos propostos contemplam o agendamento de dispositivos que possuem características para aplicação em residências ou qualquer sistemas de gerenciamento de cargas similares, e que contribuem significativamente para a demanda.

A Tabela 4.1 apresenta a potência média, duração de um ciclo de funcionamento e o período proposto de referência para o funcionamento dos dispositivos. Destaca-se que neste caso não estão sendo identificados o tipo e a descrição dos equipamentos utilizados. Entretanto, salienta-se que os valores de potência considerados estão de acordo com diversos equipamentos que possam vir a participar de um sistema de gerenciamento e agendamento de carga conforme considerados em (SIEBERT et al., 2012), (KHALID et al., 2018) e (JAVAID et al., 2017).

Tabela 4.1 – Lista de cargas consideradas para o agendamento

| Carga | Potência P_i | L_i | $m_{1,(i)}^{\min} - m_{1,(i)}^{\max}$ |
|----------|----------------|-------|---------------------------------------|
| Carga 1 | 400 | 1 | 17 – 23 |
| Carga 2 | 2500 | 2 | 7 – 23 |
| Carga 3 | 2000 | 3 | 10 – 20 |
| Carga 4 | 800 | 4 | 1 – 10 |
| Carga 5 | 1500 | 1 | 6 – 17 |
| Carga 6 | 400 | 2 | 0 – 23 |
| Carga 7 | 2500 | 3 | 0 – 23 |
| Carga 8 | 2000 | 4 | 0 – 23 |
| Carga 9 | 800 | 1 | 0 – 23 |
| Carga 10 | 1500 | 2 | 0 – 23 |

Com relação ao tempo de operação das cargas L_i , os valores foram especificados de forma que pudessem apresentar uma diversidade de características, possibilitando então a análise do comportamento dos algoritmos diante de tal situação.

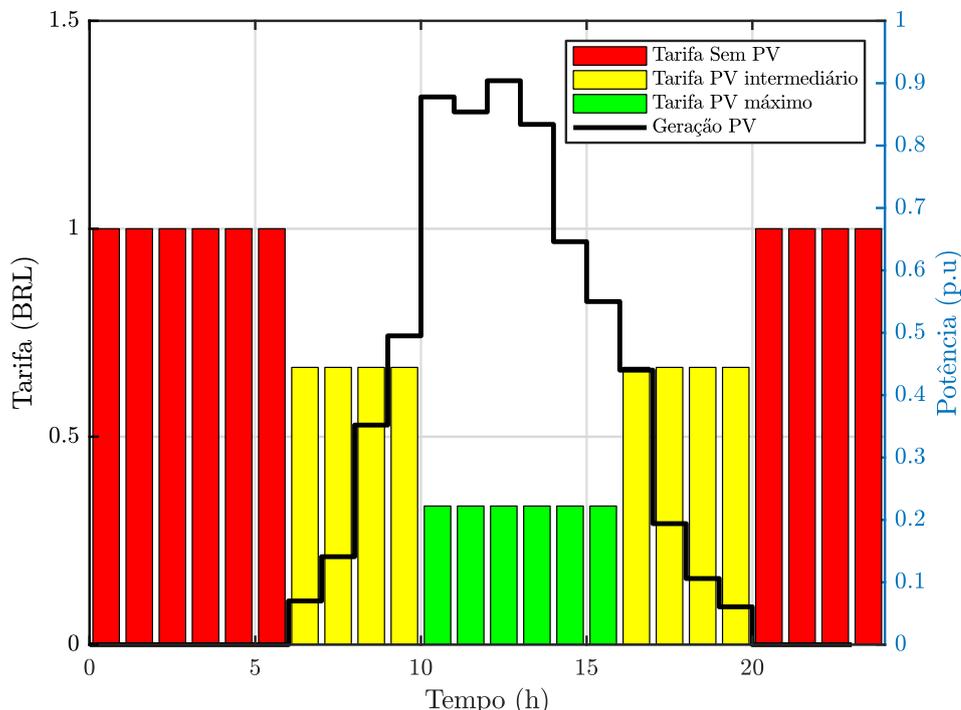
Destaca-se ainda que os algoritmos implementados possuem capacidade de adaptação, para quaisquer valores de potência de cargas P_i , quaisquer tempo de duração L_i e que as restrições de horários podem ser atribuídas de acordo com interesse do usuário.

Com relação às restrições de períodos de funcionamento, considerou-se que metade das cargas não apresentam restrição de intervalos de tempo para operação.

O modelo tarifário de resposta à demanda aplicado nas simulações considera a utilização de tarifas que podem variar ao longo do dia.

O primeiro modelo tarifário considerado apresenta custo inverso à curva de geração de um sistema fotovoltaico, conforme Figura 4.1. Este modelo, embora não possua regulamentação para a sua utilização, colabora para que ocorra o deslocamento de cargas para os momentos de maior radiação solar, evitando fenômenos como *Duck-curve*. A curva de referência de geração fotovoltaica utilizada para a discretização de patamares tarifário baseou-se na curva descrita por Azevedo (2017).

Figura 4.1 – Modelo de tarifa aplicado nas simulações, inversamente proporcional à curva de geração fotovoltaica.

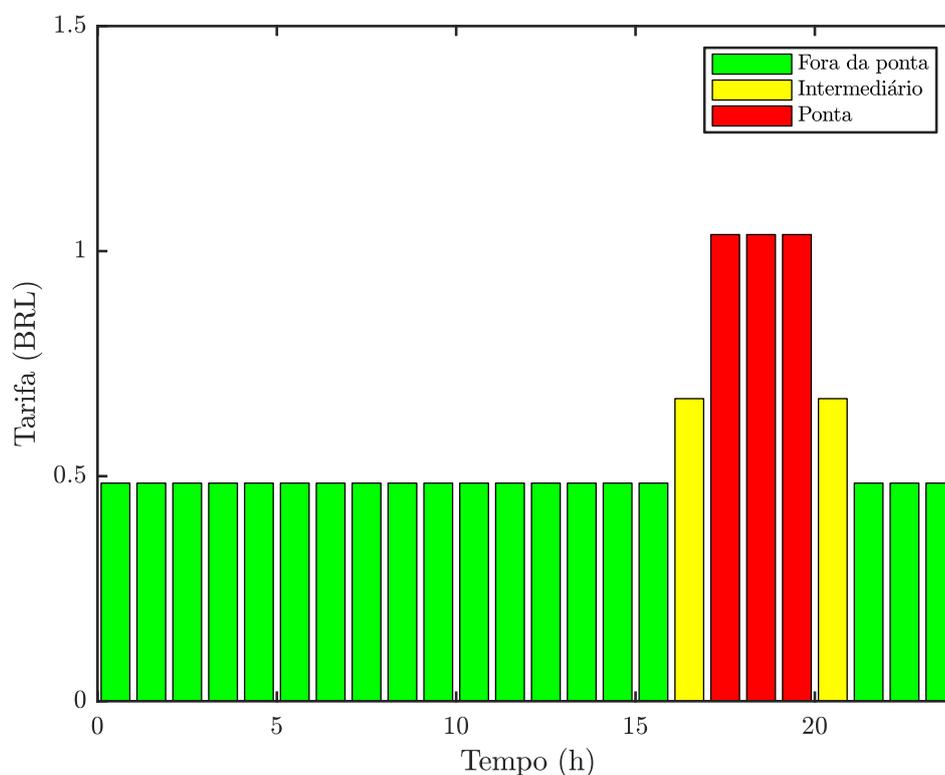


Fonte: Elaborada pelo autor

O segundo modelo tarifário utilizado considerou a utilização da tarifa branca, modelo em vigor no Brasil, conforme Figura 4.2. A tarifa horária branca é uma opção de tarifa *Time Of Use (ToU)* que apresenta valores diferenciados ao consumidor, de acordo com o horário

de utilização da energia. Para aplicação da tarifa branca, torna-se importante a definição dos períodos de ponta, fora ponta e intermediário, sendo que a definição dos mesmos deve ser proposta pela distribuidora e submetida à aprovação da ANEEL.

Figura 4.2 – Modelo de tarifa aplicado nas simulações, Tarifa Branca.



Fonte: Elaborada pelo autor

As seguintes imposições devem ser observadas:

- i. o horário de ponta deve ter a duração de três horas consecutivas e ser aplicado em cinco dias da semana,
- ii. o horário intermediário deve ser uma hora imediatamente anterior e uma hora imediatamente posterior ao período de ponta,
- iii. e os demais períodos são considerados fora da ponta.

No Brasil, a tarifa branca começou a ser implementada para clientes de baixa tensão a partir de Janeiro de 2018. No primeiro ano, somente clientes com consumo médio de 500 kWh/mês podem fazer a sua adesão. Desde Janeiro de 2019, os clientes com consumo médio de 250 kWh/mês puderam aderir a este modelo tarifário.

4.2 PARÂMETROS UTILIZADOS NOS ALGORITMOS

Diante da elaboração dos algoritmos, alguns parâmetros considerados são de extrema importância para a execução dos mesmos. Para a simulação do método utilizando deslocamentos aleatórios, o principal parâmetro refere-se ao número de iterações. Sendo assim, nestas simulações considera-se 50×10^3 iterações.

Os parâmetros do *PSO* levados em consideração são o número de iterações realizadas, quantidade de partículas utilizadas sendo que cada uma representa um possível solução para agendamento e as constantes de aceleração c_1 e c_2 e de inércia w . Os valores adotados para as simulações encontram-se descritos na Tabela 4.2.

Note que o “número de iterações” do *PSO* vezes o seu “número de partículas” resulta no mesmo número de iterações escolhido para o método com deslocamentos aleatórios. Esse ajuste é importante para questões de comparação de ordem de complexidade e velocidade de convergência, visto que cada partícula do *PSO* pode ser considerada como a execução de um (1) processo de agendamento.

Tabela 4.2 – Parâmetros *PSO*

| Parâmetro | Valor utilizado |
|----------------|-----------------|
| Iterações | 1×10^3 |
| Partículas | 50 |
| $c_{1inicial}$ | 2 |
| c_{1final} | 0,25 |
| $c_{2inicial}$ | 2 |
| c_{2final} | 0,25 |
| w_{ini} | 0,9 |
| w_{final} | 0,2 |

Fonte: Elaborada pelo autor

Com relação ao *EPSO*, os parâmetros de número de iterações e partículas não se alteram quando comparado ao *PSO*. A regra de movimento mantém seus termos de inércia, memória e cooperação, enquanto que as constantes de aceleração são substituídas por uma variável aleatória com distribuição Gaussiana normal (média 0 e variância 1) acrescida ao valor de inércia, conforme proposto por Miranda e Fonseca (2002b). Assim, são consideradas os seguintes parâmetros conforme Tabela 4.3.

Tabela 4.3 – Parâmetros *EPSO*

| Parâmetro | Valor utilizado |
|------------|-----------------|
| Iterações | 1×10^3 |
| Partículas | 50 |
| r | 2 |

Fonte: Elaborada pelo autor

4.3 RESULTADO DAS SIMULAÇÕES CONSIDERANDO CARGAS AGENDÁVEIS

4.3.1 Cenário A para o agendamento considerando um número reduzido de cargas

Inicialmente são apresentados os resultados de simulações considerando os valores máximo ($z = 1$) e mínimo ($z = 0$) do peso z em (3.28).

4.3.1.1 Cenário A considerando $z = 1$ para F_{obj}

Ao considerar $z = 1$, somente a métrica de custo torna-se efetiva na busca de agendamento de F_{obj} . A Equação (3.28) pode então ser expressa da seguinte forma:

$$F_{obj} = z \times \text{Custo} \quad (4.1)$$

Ao considerar somente esta métrica, evidencia-se neste caso que as cargas tenderão a ser agendadas nos intervalos de menor tarifa aplicada, desde que o intervalo de menor tarifa esteja compreendido entre $m_{1,(i)}^{\min}$ e $m_{1,(i)}^{\max}$ para cada uma das cargas. A Figura 4.3, apresenta a curva de carga para o agendamento para os 3 métodos implementados. Destaca-se que as referidas curvas apresentam somente as cargas que participam do mecanismo de agendamento.

Observa-se através da Figura 4.3 que os 3 métodos apresentam soluções semelhantes, realizando o agendamento das cargas nos momentos de menor tarifa. Destaca-se que algumas cargas não podem ser agendadas no instante de menor tarifa devido às restrições para o seu intervalo de operação. A Carga 1 e a Carga 4 refletem esta situação, ao passo que nenhuma delas pode ser agendada no momento de PV máximo, o qual incide no momento de menor tarifa.

A Tabela 4.4 apresenta o custo e PAPER para os métodos implementados considerando o peso $z = 1$.

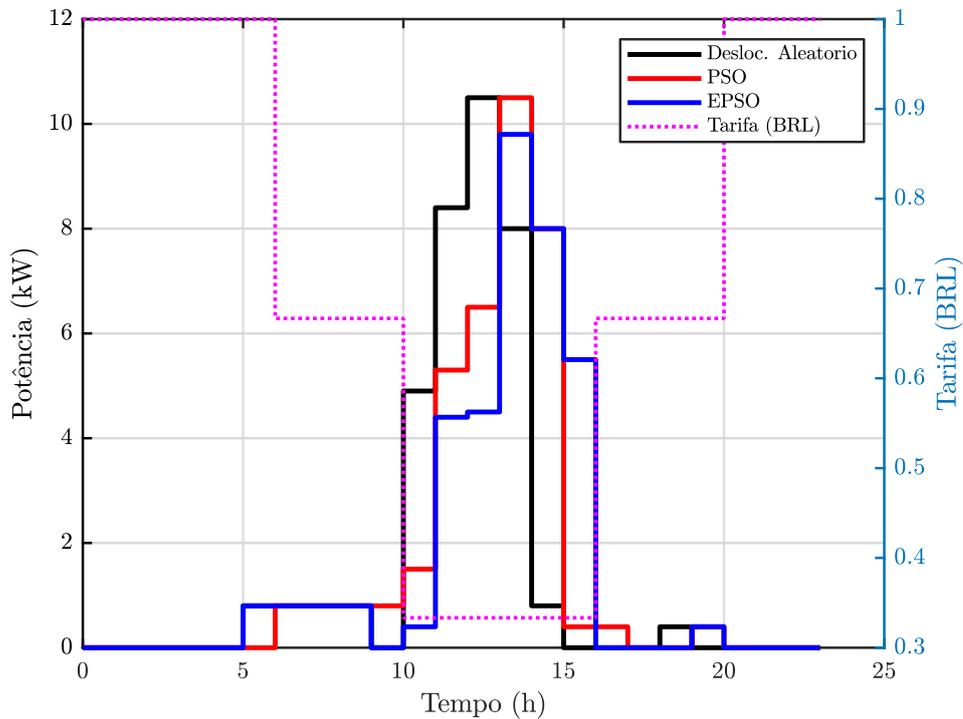
Tabela 4.4 – Resultado das métricas dos algoritmos considerando $z = 1$.

| Métrica | Deslocamento aleatório | PSO | EPSO |
|-------------|------------------------|--------|-------|
| Custo (BRL) | 13.53 | 13.40 | 13.53 |
| PAPER | 6.9613 | 6.9613 | 6.5 |

Fonte: Elaborada pelo autor

A Tabela 4.5 apresenta os instantes de tempo que cada uma das cargas começa o seu funcionamento considerando, os 3 métodos implementados.

Figura 4.3 – Simulação para $N = 10$, $z = 1$, levando em consideração somente a métrica de custo para os três métodos implementados. Tarifa inverso a curva de geração PV.



Fonte: Elaborada pelo autor

Tabela 4.5 – Horário de início de funcionamento das cargas considerando $z = 1$.

| Cargas | $m_{1,(i)}^{\min} - m_{1,(i)}^{\max}$ | L_i | Horário inicial de operação da carga. Deslocamento aleatório. | Horário inicial de operação da carga PSO | Horário inicial de operação da carga EPSO |
|----------|---------------------------------------|-------|---|---|--|
| Carga 1 | 17 - 23 | 1 | 18 h | 19 h | 19 h |
| Carga 2 | 7 - 23 | 2 | 12 h | 13 h | 13 h |
| Carga 3 | 10 - 20 | 3 | 11 h | 12 h | 13 h |
| Carga 4 | 1 - 10 | 4 | 5 h | 6 h | 5 h |
| Carga 5 | 6 - 17 | 1 | 11 h | 10 h | 11 h |
| Carga 6 | 0 - 23 | 2 | 10 h | 15 h | 10 h |
| Carga 7 | 0 - 23 | 3 | 10 h | 11 h | 11 h |
| Carga 8 | 0 - 23 | 4 | 10 h | 11 h | 12 h |
| Carga 9 | 0 - 23 | 1 | 14 h | 11 h | 13 h |
| Carga 10 | 0 - 23 | 2 | 12 h | 13 h | 14 h |

Fonte: Elaborada pelo autor

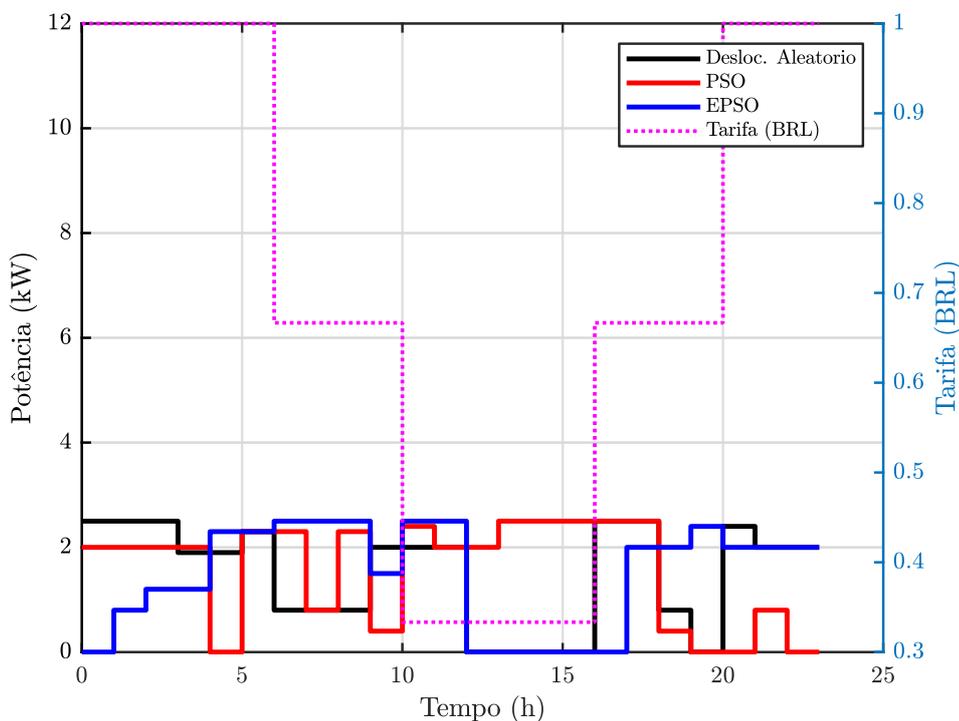
4.3.1.2 Cenário A considerando $z = 0$ para F_{obj}

Para o valor mínimo de peso na F_{obj} , $z = 0$, somente a métrica PAPR é considerada. A equação da função objetivo pode ser expressa da seguinte forma:

$$F_{obj} = (1 - z) \times \text{PAPR} \quad (4.2)$$

A Figura 4.4 apresenta a simulação para essa situação, considerando os 3 algoritmos implementados. Quando somente a métrica de PAPR é considerada, evidencia-se que as cargas tenderão a distribuir-se ao longo do espaço de agendamento, porém respeitando intervalos permitidos para o seu funcionamento. Esta situação ocorre pelo fato da função objetivo F_{obj} considerar somente a relação da potência de pico para a potência média das cargas no agendamento e desconsiderar, neste caso, a função custo.

Figura 4.4 – Simulação para $N = 10$, $z = 0$, levando em consideração somente a métrica de custo para os três métodos implementados. Tarifa inversa a curva de geração PV.



Fonte: Elaborada pelo autor

A Tabela 4.6 apresenta o custo e PAPR para cada um dos métodos implementados e considerando o peso $z = 0$.

Tabela 4.6 – Resultado das métricas dos algoritmos considerando $z = 0$

| Métrica | Deslocamento aleatório | PSO | EPSO |
|-------------|------------------------|--------|--------|
| Custo (BRL) | 30.13 | 23.20 | 27.73 |
| PAPR | 1.6575 | 1.6575 | 1.6575 |

Fonte: Elaborada pelo autor

Percebe-se que o custo apresentou diferentes valores para os 3 métodos implementados. Isto ocorre pois, nesta situação, o custo não apresenta influência sobre F_{obj} . A Tabela 4.7 apresenta os instantes de tempo que cada uma das cargas começa o seu funcionamento, considerando os 3 métodos implementados.

Tabela 4.7 – Horário de início de funcionamento das cargas considerando $z = 0$.

| Cargas | $m_{1,(i)}^{\min} - m_{1,(i)}^{\max}$ | L_i | Horário inicial de operação da carga. Deslocamento aleatório. | Horário inicial de operação da carga PSO | Horário inicial de operação da carga EPSO |
|----------|---------------------------------------|-------|--|--|---|
| Carga 1 | 17 - 23 | 1 | 20 h | 18 h | 19 h |
| Carga 2 | 7 - 23 | 2 | 16 h | 13 h | 10 h |
| Carga 3 | 10 - 20 | 3 | 9 h | 10 h | 17 h |
| Carga 4 | 1 - 10 | 4 | 5 h | 5 h | 1 h |
| Carga 5 | 6 - 17 | 1 | 5 h | 8 h | 9 h |
| Carga 6 | 0 - 23 | 2 | 3 h | 9 h | 2 h |
| Carga 7 | 0 - 23 | 3 | 0 h | 15 h | 6 h |
| Carga 8 | 0 - 23 | 4 | 20 h | 0 h | 20 h |
| Carga 9 | 0 - 23 | 1 | 18 h | 21 h | 5 h |
| Carga 10 | 0 - 23 | 2 | 3 h | 6 h | 4 h |

Fonte: Elaborada pelo autor

4.3.1.3 Cenário A considerando $0 \leq z \leq 1$ para F_{obj}

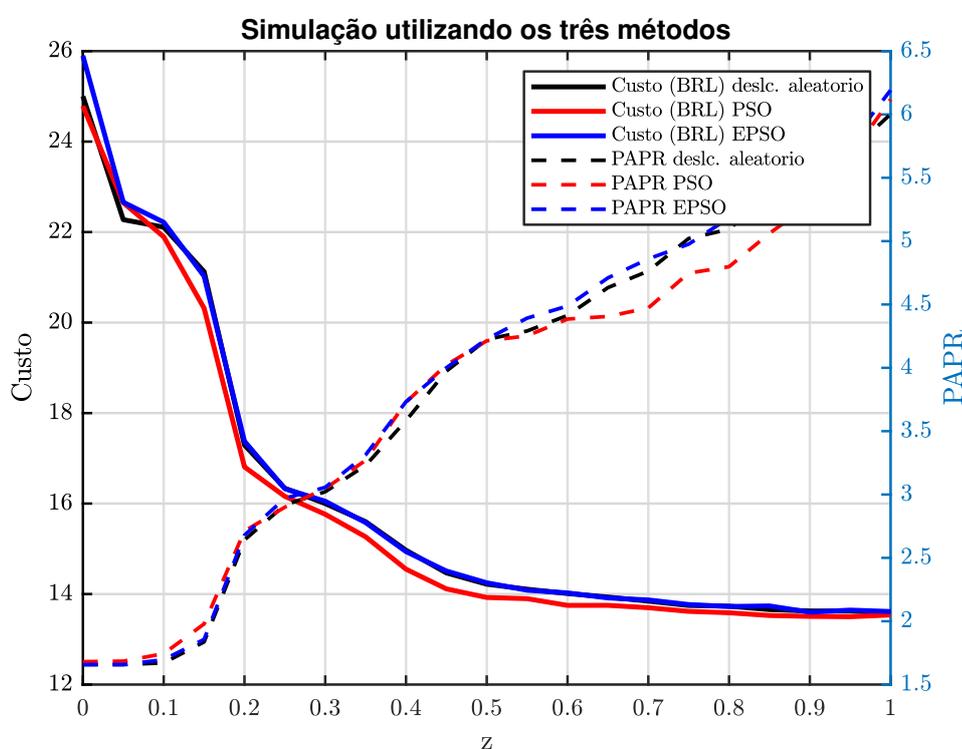
Considerando a função de otimização (3.28), sabe-se que a variação do parâmetro z influencia diretamente no comportamento da função objetivo e, conseqüentemente, nos valores das métricas de custo e PAPR.

Tomando como referência as cargas da Tabela 4.1, realizaram-se simulações para cada variação de z nos 3 algoritmos implementados. De acordo com a modelagem, definiu-se que intervalo para z deve ser $0 \leq z \leq 1$. Variando z neste intervalo, a um passo 0.05,

foram executadas 100 realizações de otimização, para cada passo e em cada um dos métodos implementados, a fim de tomar a média sobre as incertezas do resultado de cada método.

A Figura 4.5 apresenta os valores da métrica de custo e de PAPR para cada um dos valores de z das simulações realizadas para os três métodos. Através desta análise, percebe-se o comportamento de F_{obj} diante de cada peso aplicado. O gráfico torna-se uma ferramenta importante para a parametrização do comportamento que se deseja obter com o uso dos algoritmos.

Figura 4.5 – Simulação para para os 3 métodos implementados com z variando no intervalo $0 \leq z \leq 1$ com passo 0.05 e $N = 10$ equipamentos. Tarifa inversamente proporcional à curva de geração fotovoltaica (PV).



Fonte: Elaborada pelo autor

4.3.1.4 Cenário A considerando $z = 0.25$ para F_{obj}

Analisando os 3 métodos aplicados com um variação de z conforme a Figura 4.5, identifica-se para este conjunto de cargas um ponto de intersecção entre as duas métricas abordadas e pode-se dizer que este ponto representa o ótimo de Pareto.

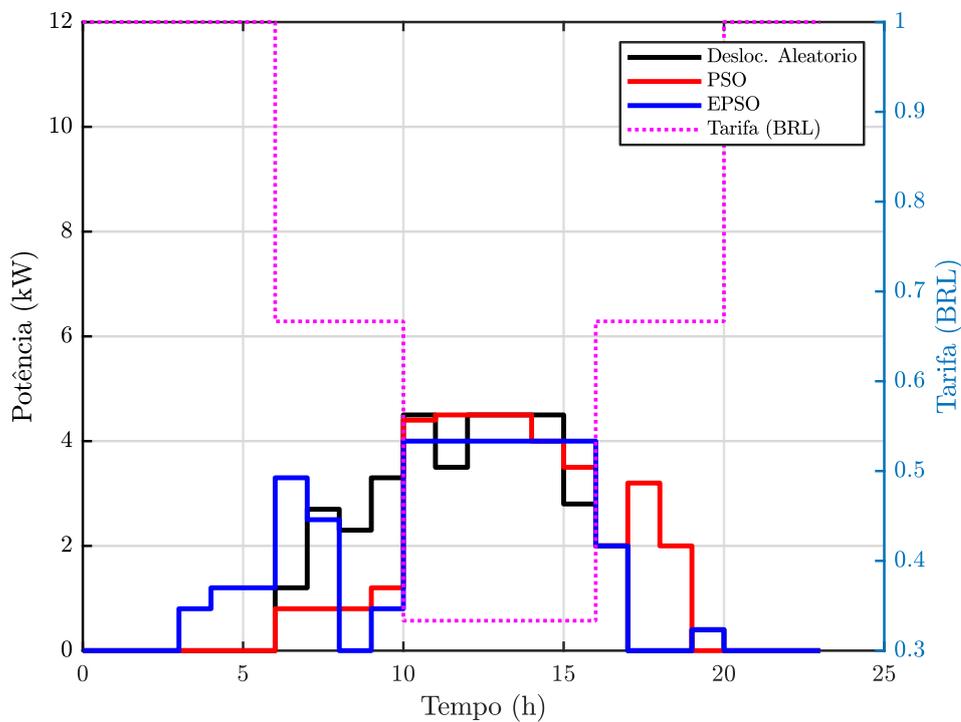
O ótimo de Pareto representa um estado de alocação de recursos a partir do qual é impossível realocar para melhorar qualquer indivíduo ou critério de preferência, sem piorar pelo menos um critério de preferência ou indivíduo. Na modelagem, abordada tem-se um

ponto que apresenta a melhor solução considerando as duas métricas abordadas, sendo que, para qualquer valor diferente de peso, umas das métricas será prejudicada.

Através das simulações e da Figura 4.5, identifica-se este ponto de interseção para este cenário. Assim, realizaram-se simulações para o peso $z = 0.25$, o qual representou a interseção entre as duas curvas

A Figura 4.6 apresenta as simulações com o agendamento para os 3 métodos considerando $z = 0.25$ e a Tabela 4.8 mostra os respectivos resultados obtidos para as métricas de interesse.

Figura 4.6 – Simulação para os 3 métodos com $z = 0,25$ e $N = 10$. Tarifa inversamente proporcional à curva de geração PV.



Fonte: Elaborada pelo autor

Tabela 4.8 – Resultado das métricas dos algoritmos considerando $z = 0.25$

| Métrica | Deslocamento aleatório | PSO | EPSO |
|-------------|------------------------|---------|--------|
| Custo (BRL) | 16.03 | 15.6667 | 17.20 |
| PAPR | 2.9834 | 2.9834 | 2.6519 |

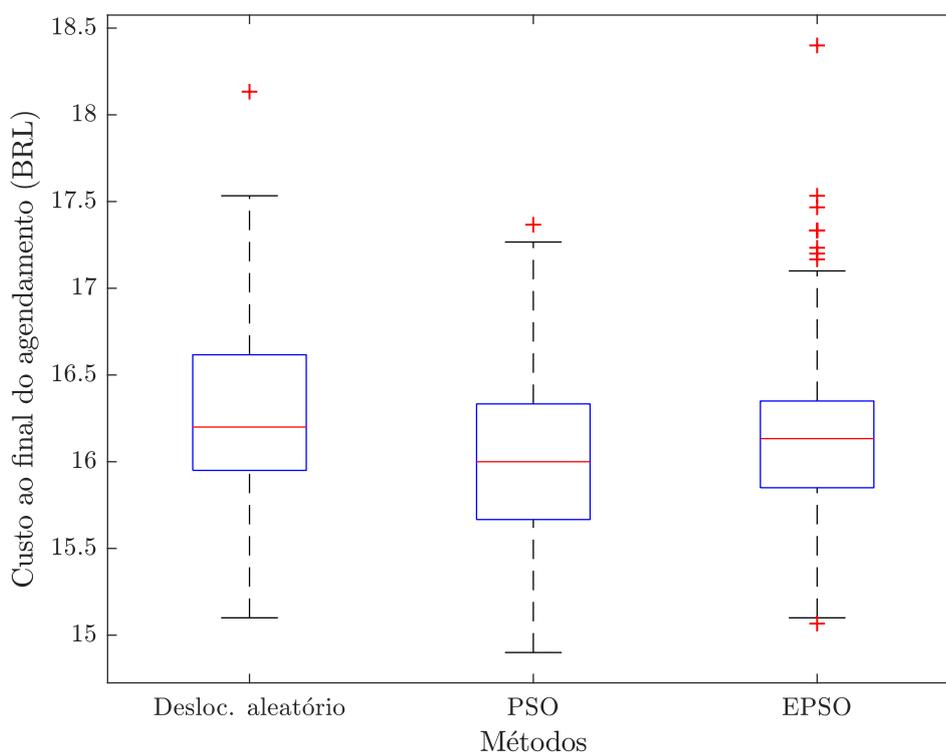
Fonte: Elaborada pelo autor

Um algoritmo heurístico não é capaz de garantir a melhor solução para um problema. Mas seu princípio é encontrar uma solução de qualidade, em um tempo adequado. Ao utilizar estes algoritmos, percebe-se que embora aproximem-se do resultado ótimo es-

perado, não encontra-se apenas uma única solução. Estes métodos costumam encontrar soluções sub-ótimas para problemas, e não soluções ótimas e definitivas.

A Figura 4.7 apresenta o *Boxplot* referente às simulações para os 3 métodos com $z = 0.25$ em um total de 100 realizações. Através deste recurso, torna-se possível representar não somente a média como também a variação dos dados observados, além das seguintes características do conjunto de dados: localização, dispersão, assimetria e outliers (medidas discrepantes).

Figura 4.7 – Simulação para os 3 métodos com $z = 0.25$, repetindo a simulação 100 vezes para $N = 10$.



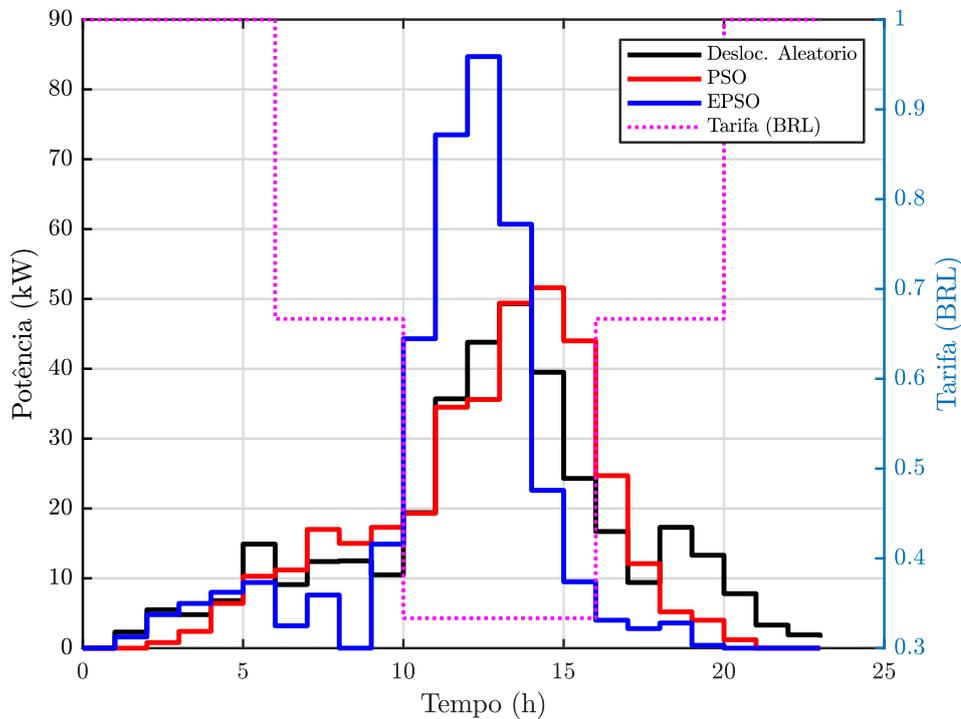
Fonte: Elaborada pelo autor

4.3.2 Cenário B para o agendamento considerando um número maior de cargas e tarifa inversamente proporcional à geração do sistema fotovoltaico

Neste cenário, foram realizadas simulações considerando um número de cargas dez (10) vezes maior do que o simulado no cenário A. Assim, serão utilizadas 100 cargas ao todo, sendo que cada grupo de 10 cargas apresenta as características consideradas na Tabela 4.1.

Destaca-se que metade dessas cargas podem ser agendadas para qualquer intervalo de tempo m , considerando a discretização considerada, de M intervalos, enquanto

Figura 4.8 – Simulação para $N = 100$ e $z = 1$, levando em consideração somente a métrica de custo para os três métodos implementados. Tarifa inversamente proporcional à curva de geração PV.



Fonte: Elaborada pelo autor

que as demais cargas ficam limitadas a um determinado período para o seu funcionamento.

Para realizar as simulações, inicialmente considerou-se somente o peso $z = 1$. Conforme descrito no cenário A, ao utilizar este peso, apenas a métrica de custo é levada em consideração. A Figura 4.8 apresenta o resultado para estas simulações.

Neste caso, todas as cargas que não possuem restrição de horário tenderam a serem agendadas no intervalo de menor custo. Percebe-se que por tratar-se de um grande número de cargas e um espaço de busca amplo, o método EPSO conseguiu explorar o espaço de busca de forma mais significativa, agendando mais cargas em um intervalo de menor custo.

A Tabela 4.9 apresenta o custo e PAPR para cada um dos métodos implementados considerando o peso $z = 1$

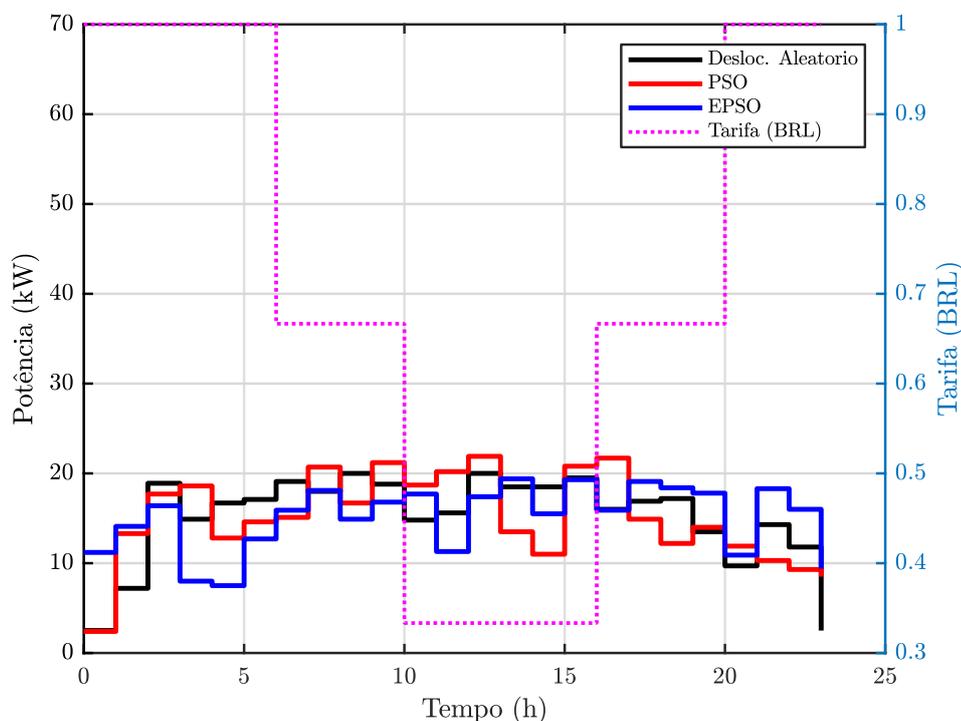
Tabela 4.9 – Resultado das métricas dos algoritmos para o cenário com 100 cargas, considerando $z = 1$ e Tarifa inversa a curva de geração fotovoltaica

| Métrica | Deslocamento aleatório | PSO | EPSO |
|-------------|------------------------|--------|--------|
| Custo (BRL) | 186.93 | 170.23 | 152.97 |
| PAPR | 3.2685 | 3.421 | 5.62 |

Fonte: Elaborada pelo autor

Na Figura 4.9, tem-se a representação de agendamento de cargas para os três métodos considerando $z = 0$. Para esta situação, a métrica de custo não está sendo considerada e as cargas estão distribuídas com o objetivo de reduzir o PAPR.

Figura 4.9 – Simulação com $N = 100$ e $z = 0$, considerando apenas a métrica de PAPR. Tarifa inversa a curva de geração fotovoltaica.



Fonte: Elaborada pelo autor

Fonte: Elaborada pelo autor

A Tabela 4.10 apresenta o custo e PAPR para cada um dos métodos implementados considerando o peso $z = 0$. Novamente o *EPSO* mostra-se mais eficiente que os demais algoritmos.

Tabela 4.10 – Resultado das métricas dos algoritmos para o cenário com 100 cargas, considerando $z = 0$ e curva de tarifa inversamente proporcional à curva de geração fotovoltaica.

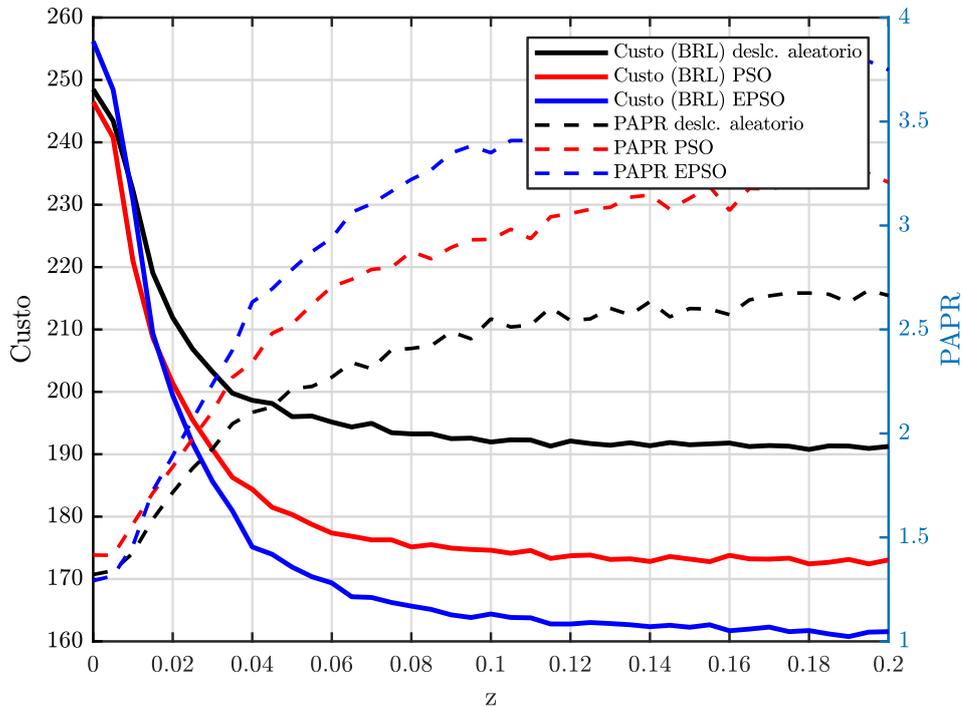
| Métrica | Deslocamento aleatório | PSO | EPSO |
|-------------|------------------------|--------|--------|
| Custo (BRL) | 244.23 | 245.76 | 249.3 |
| PAPR | 1.326 | 1.4519 | 1.2862 |

Fonte: Elaborada pelo autor

Conforme realizado no cenário A, baseado na função de otimização definida na Equação (3.28), realizaram-se simulações para a variação de $z \in [0, 1]$ para analisar a

influência do peso nos valores das métricas de custo e PAPR. Foram realizadas 100 simulações para cada valor de z , a um passo de variação de 0.005, considerando $0 \leq z \leq 1$. Na Figura 4.10 é apresentado os resultados das simulações para este cenário.

Figura 4.10 – Simulação para para os 3 métodos implementados com z variando a um passo 0.005. $0 \leq z \leq 1$, $N = 100$, Tarifa inverso à curva de geração PV.



Fonte: Elaborada pelo autor

Destaca-se que, devido ao acréscimo de carga realizado neste cenário, a função custo apresenta sensibilidade com relação ao incremento de cargas, devido à alteração na sua escala de energia consumida, enquanto que a escala da PAPR mantém-se insensível ao incremento de cargas (devido à normalização da média e sua proporcionalidade com o pico).

O acréscimo de cargas também faz com que a região onde encontra-se o ótimo de Pareto se desloque para a esquerda, acontecendo em uma faixa de valores de z que é inversamente proporcional a esse aumento. Uma estratégia para mitigar tal situação, mantendo a busca de z dentro do intervalo $0 \leq z \leq 1$ sem prejuízo da realização de buscas em regiões “inúteis” desse parâmetro, pode ser realizada através de uma normalização da função objetivo, a qual não é realizada neste trabalho.

Analisando o comportamento dos algoritmos para um número maior de cargas, percebe-se que o ponto de Pareto variou para cada um dos métodos implementados. Assim, cada um dos métodos encontrou um ponto z próprio onde ocorre o encontro das duas métricas envolvidas.

Os algoritmos implementados nesta modelagem tendem a saturar em uma determi-

nada região e, por mais que altere-se parâmetros como número de iterações e números de partículas, os mesmos não conseguem apresentar respostas melhores. Tal situação ocorre pois o espaço da busca é amplo, tornando-se difícil a exploração e estratégias devem ser incorporados aos métodos para que obtenha-se resultados melhores.

Através da Figura 4.10, percebe-se que o algoritmo *EPSO* apresentou resultados superiores quando comparados aos demais métodos implementados. Percebe-se que, mesmo com um número grande de cargas, o método conseguiu caracterizar de forma clara sua resposta para variações do peso z .

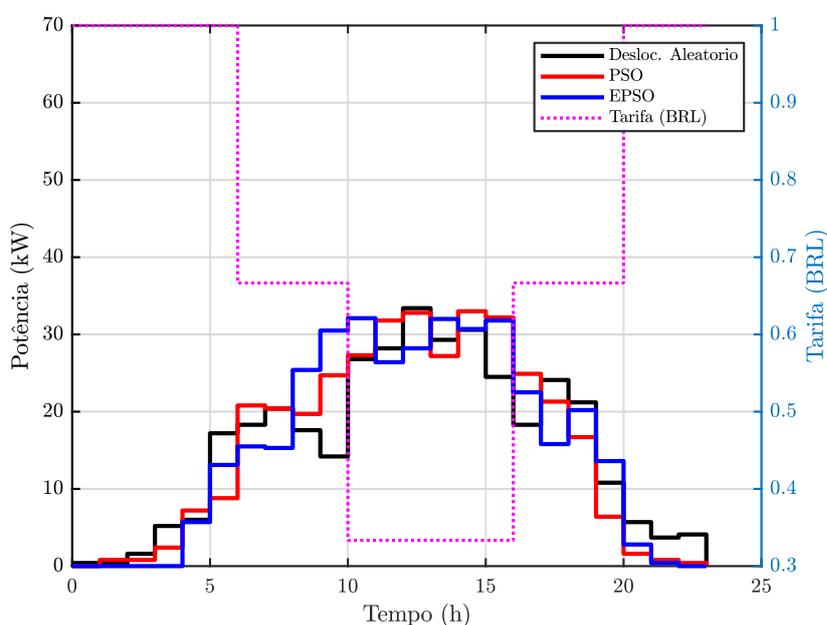
Através da Figura 4.10, identificou-se os pontos de Pareto e, com os respectivos pesos ótimos, realizaram-se as simulações para cada um desses valores, cujos resultados encontram-se descritos na Tabela 4.11. A Figura 4.11 apresenta as curvas de agendamento de carga para cada um dos pesos considerados.

Tabela 4.11 – Resultado das métricas dos algoritmos para o cenário com 100 cargas, considerando ponto de Pareto para cada método. Curva de tarifa inversa a curva PV

| Métrica | Deslocamento | <i>PSO</i> | <i>EPSO</i> |
|-------------|--------------------------|------------|-------------|
| | aleatório $z = 0.045$ | $z = 0.03$ | $z = 0.025$ |
| Custo (BRL) | 198.5 | 187.5 | 182.5 |
| PAPR | 2.2144 | 2.1878 | 2.12 |

Fonte: Elaborada pelo autor

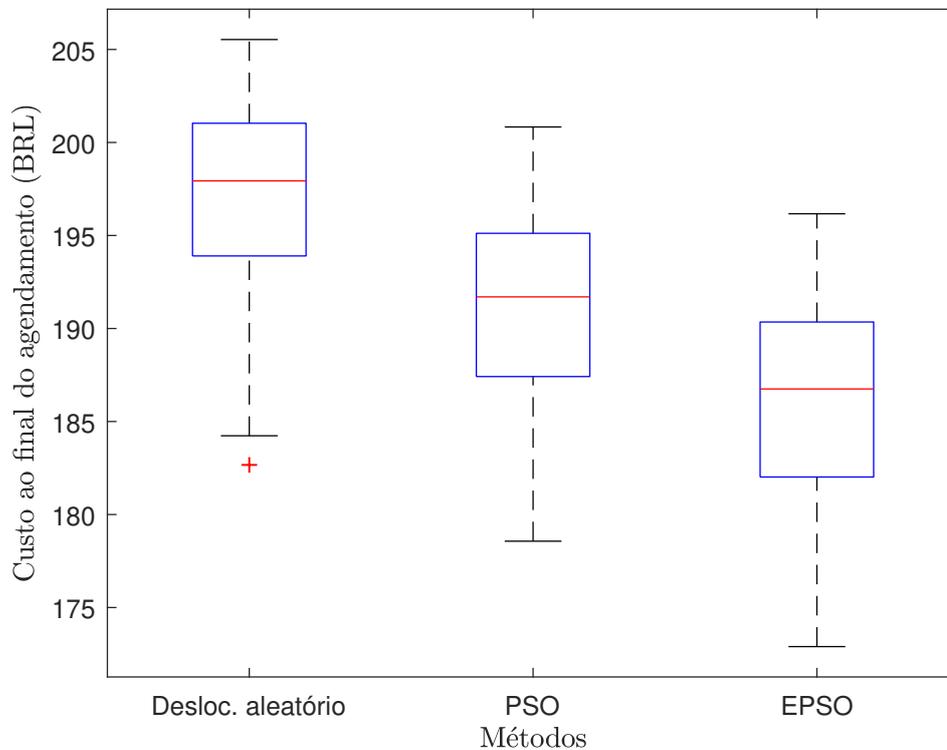
Figura 4.11 – Simulação para os 3 métodos considerando o ponto de Pareto para o agendamento de $N = 100$ cargas.



Fonte: Elaborada pelo autor

A Figura 4.12 apresenta o *Boxplot* referente às simulações para os 3 métodos, com seus respectivos pesos ótimos de Pareto, em um total de 100 realizações.

Figura 4.12 – Simulação para os 3 métodos no ponto de Pareto, repetindo a mesma simulação 100 vezes. $N = 100$.



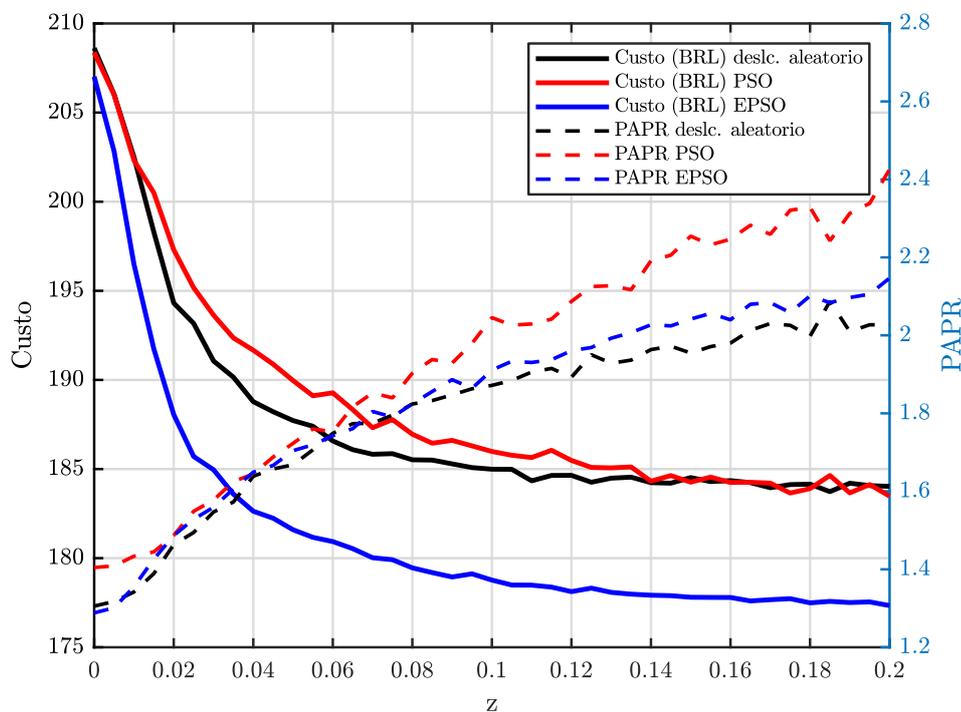
Fonte: Elaborada pelo autor

4.3.3 Cenário C para o agendamento considerando um número maior de cargas e aplicando a tarifa branca

Com o objetivo de analisar o comportamento dos 3 algoritmos implementados, foram realizadas simulações considerando a utilização da tarifa branca atualmente em vigor no Brasil. Nesta situação, considerou-se a utilização de 100 cargas, sendo que 50 cargas podem ser agendadas em qualquer intervalo de tempo ao longo dos M slots de tempo considerados, e as demais possuem somente algum intervalo em que podem ser agendadas.

Baseado na função de otimização definida na Equação 3.28, e com o objetivo de analisar o comportamento para este modelo tarifário, realizaram-se simulações para a variação de z , para analisar a influência do peso nos valores das métricas de custo e PAPR. A Figura 4.13 apresenta as simulações para o método utilizando a tarifa branca através da variação do peso z considerando uma variação a um passo de 0.005.

Figura 4.13 – Simulação para os 3 métodos com considerando variação de z a um passo de 0.005, repetindo a simulação 100 vezes para cada peso em um cenário com $N = 100$ cargas e considerando tarifa branca.



Fonte: Elaborada pelo autor

Conforme evidenciado nos outros cenários simulados e também através da Figura 4.13, o método *EPSO* apresenta melhor resposta quando comparado aos demais métodos e consegue explorar melhor o espaço de busca na modelagem do sistema proposto.

A Figura 4.14 apresenta a curva com agendamento de carga para este método considerando o ponto de Pareto em $z = 0.035$. Através deste ponto, é possível realizar o melhor agendamento possível para o número de cargas e obter o melhor das duas métricas sem uma das métricas prejudicar a outra.

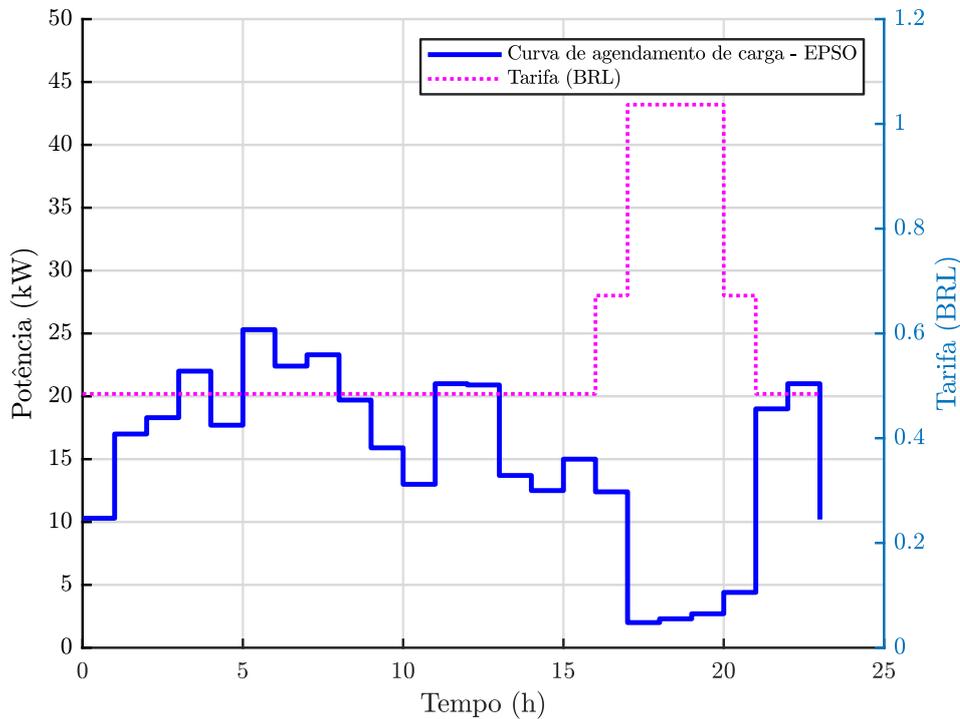
A Tabela 4.12 apresenta o custo e PAPR para o método *EPSO* considerando os pesos do ponto de Pareto o *EPSO*.

Tabela 4.12 – Resultado das métricas para o ESPO no cenário com 100 cargas, considerando ponto de Pareto. Tarifa branca

| Métrica | EPSO $z = 0.035$ |
|-------------|----------------------------|
| Custo (BRL) | 182.41 |
| PAPR | 1.6713 |

Fonte: Elaborada pelo autor

Figura 4.14 – Simulação para o método EPSO no ponto de pareto considerando $z = 0.035$, $N = 100$ e tarifa branca



Fonte: Elaborada pelo autor

4.4 ANÁLISE DE RESULTADOS REFERENTE AOS 3 MÉTODOS IMPLEMENTADOS

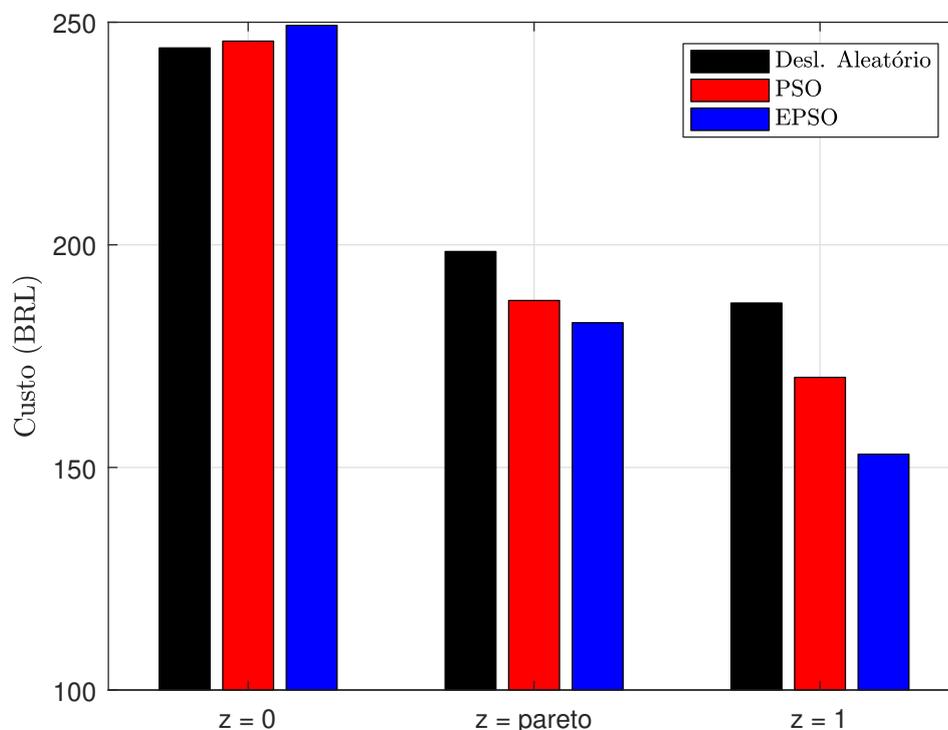
A utilização de métodos heurísticos auxilia quando se busca encontrar soluções para problemas com grande número de possibilidades e que a resposta deva ser obtida de forma rápida. Neste trabalho, através da implementação de 3 métodos com heurísticas diferentes, percebe-se a importância que as mesmas apresentam na obtenção destes resultados.

Os três métodos implementados apresentam complexidade de implementação diferentes para a modelagem considerada. O primeiro método de solução única no estilo *Greedy search* pode ser considerado como o mais simples de implementação, enquanto que o método de otimização por Enxame de partículas (*PSO*) e evolutivos (*EPSO*) possuem uma maior complexidade e maior capacidade de exploração de resultados.

Analisando os resultados percebe-se que para um número reduzido de cargas os 3 métodos apresentaram resultados muito semelhantes. Quando simulado com $N = 10$ cargas para os 3 métodos, verificou-se que, embora os instantes de agendamento das cargas possam não ocupar os mesmos *slots* de tempo, os resultados para qualquer peso z considerado proporcionou resultados de métricas Custo e PAPR muito próximos entre os

métodos implementados.

Figura 4.15 – Resultados obtidos para os 3 métodos implementados referente ao custo. $z = 0$ considera somente a métrica de PAPR, $z = 1$ considera somente a métrica de custo e $z = \text{Pareto}$ apresenta o ponto de equilíbrio entre as duas métricas.



Fonte: Elaborada pelo autor

Essa situação ocorre pois adotou-se discretização horária o que reduz o número de *slots* de tempo necessário, e também pelo fato da utilização de número reduzido de cargas, o que possibilita ao algoritmo percorrer um subespaço grande, relativamente ao tamanho total espaço de busca, e mesmo nas heurísticas mais simples (primeiro caso implementado) o algoritmo possui a capacidade de encontrar uma resposta adequada.

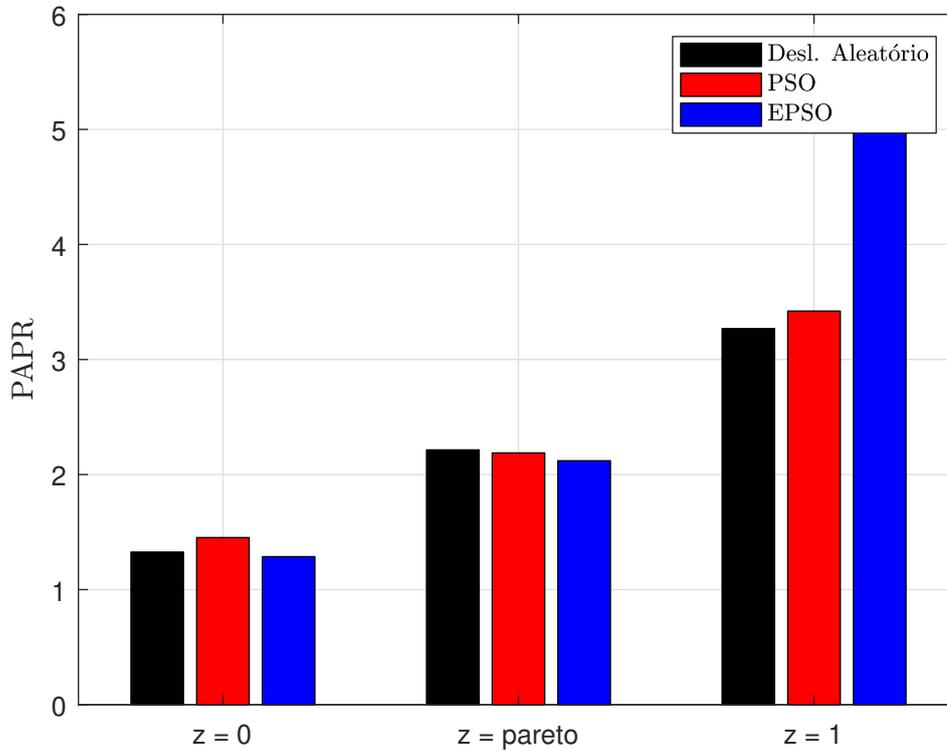
Entretanto, quando o problema passa a ter um espaço de busca maior, com um número maior de cargas ou discretização em menores intervalos de tempo, o espaço de busca se torna muito amplo, dificultando algoritmos que apresentem heurísticas mais simplificadas de encontrarem melhores resultados. Nesses casos, percebe-se diferenças consideráveis no resultados.

Para a situação com 100 cargas, ao analisarmos os 3 métodos implementados para esta modelagem, percebe-se que método de otimização *EPSO* apresentou resultados superiores neste cenário com amplo espaço de busca quando comparado ao outros dois métodos. Destaca-se aqui que o algoritmo com deslocamentos aleatórios apresentou resultado inferior quando comparada com o método de otimização *PSO*.

As Figuras 4.15 e 4.16 apresentam um comparativo desses resultados para o cada um dos pesos considerados na simulações, considerando o caso com 100 cargas e o

modelo tarifário com custo inversamente proporcional à curva geração de um sistema fotovoltaico.

Figura 4.16 – Resultados obtidos para os 3 métodos implementados referente ao PAPR. $z = 0$ considera somente a métrica de PAPR, $z = 1$ considera somente a métrica de custo e $z = \text{Pareto}$ apresenta o ponto de equilíbrio entre as duas métricas.



Fonte: Elaborada pelo autor

Para os as simulações realizadas no cenário de 100 cargas descritas nas Figuras 4.15 e 4.16 o agendamento no método de solução única (desloc. Aleatórios) apresentou tempo de execução de $10.53s$, no método *PSO* tempo de $6.93s$ e *EPSO* tempo de execução de $7.52s$.

Assim, destaca-se que os métodos implementados, independente da heurística e considerações implementadas apresentaram uma capacidade muito rápida de obter o resultado, sendo que para, todos os cenários, o tempo para o método apresentar o resultado de agendamento se mostrou satisfatório para potencial aplicações em redes elétrica inteligentes.

4.5 RESUMO DO CAPÍTULO

Neste capítulo, foram apresentados os resultados das simulações referentes aos métodos implementados para realização do agendamento de cargas. Inicialmente, foram

apresentadas as premissas referentes aos métodos implementados e considerações para os algoritmos de agendamento.

Após, são apresentadas as simulações realizadas comparando os 3 métodos implementados (busca local com deslocamento aleatórios, *PSO* e *EPSO*) e a análise dos resultados obtidos considerando o agendamento de um número reduzido de cargas e com dez vezes mais cargas que o cenário de cargas reduzidas. Nesses cenários, buscou-se avaliar as respostas dos algoritmos e não considera-se as parcelas de carga não deslocáveis.

Por fim são apresentados resultados obtidos para valores das métricas com as simulações referentes aos 3 métodos implementados, através da comparação de cenários idênticos considerando os diferentes valores de pesos implementados.

5 ESTUDO DE CASO APLICADO

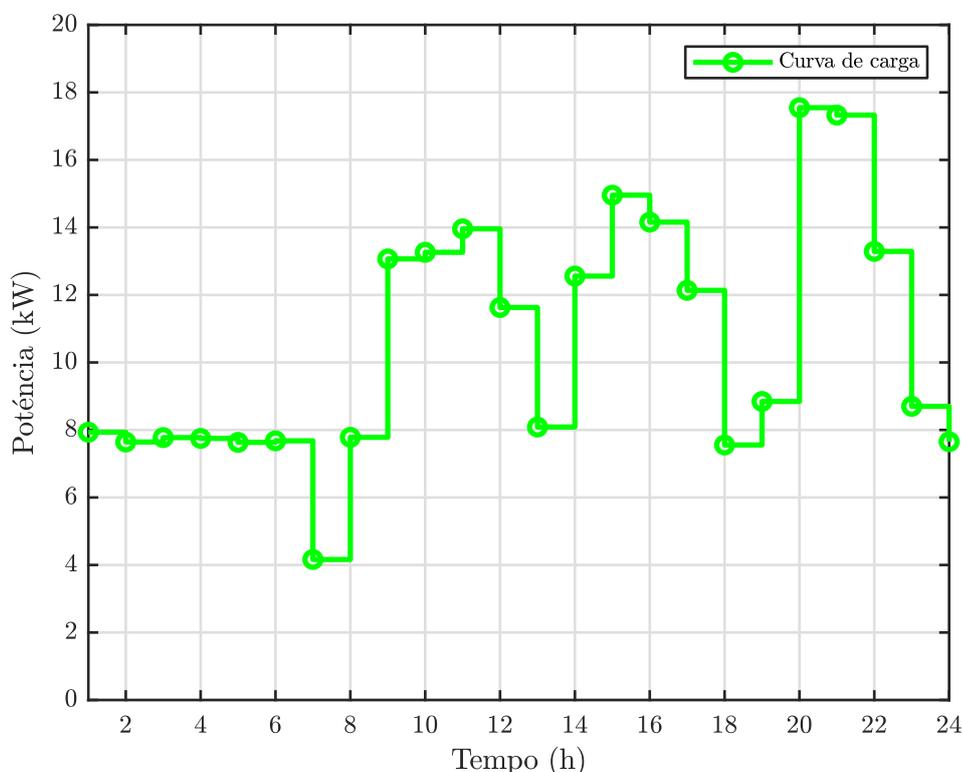
De acordo com os resultados apresentados no Capítulo 4 para o agendamento de cargas para os 3 métodos implementados, o método *EPSO* apresentou resultados superiores em relação aos outros implementados. Destaca-se ainda que neste trabalho o método *EPSO* aplicado refere-se a primeira versão proposta por Miranda e Fonseca (2002b) e embora não seja a versão mais eficiente, observa-se que a mesma tem melhor comportamento do que as outras técnicas implementadas neste trabalho.

Assim, neste Capítulo será adotado o *EPSO* para realizar as simulações de uma curva de carga real. Essa curva apresenta uma parcela de carga deslocável e uma parcela de carga não deslocável.

A curva de carga real refere-se a curva de demanda de um laboratório localizado na Universidade Federal de Santa Maria. Destaca-se que este estudo não considera se estes tipos de cargas realmente estão presentes no referido local, apenas considera-se o perfil resultante de carga do local como objeto de análise.

A Figura 5.1 apresenta o perfil de carga ao longo do dia 09 de Outubro de 2019, sendo que neste dia a energia total consumida ao final do dia foi 253.08 kWh.

Figura 5.1 – Curva de carga real considerada



Fonte: Elaborada pelo autor

O estudo pode ser dividido em dois cenários, sendo que no primeiro caso apresenta

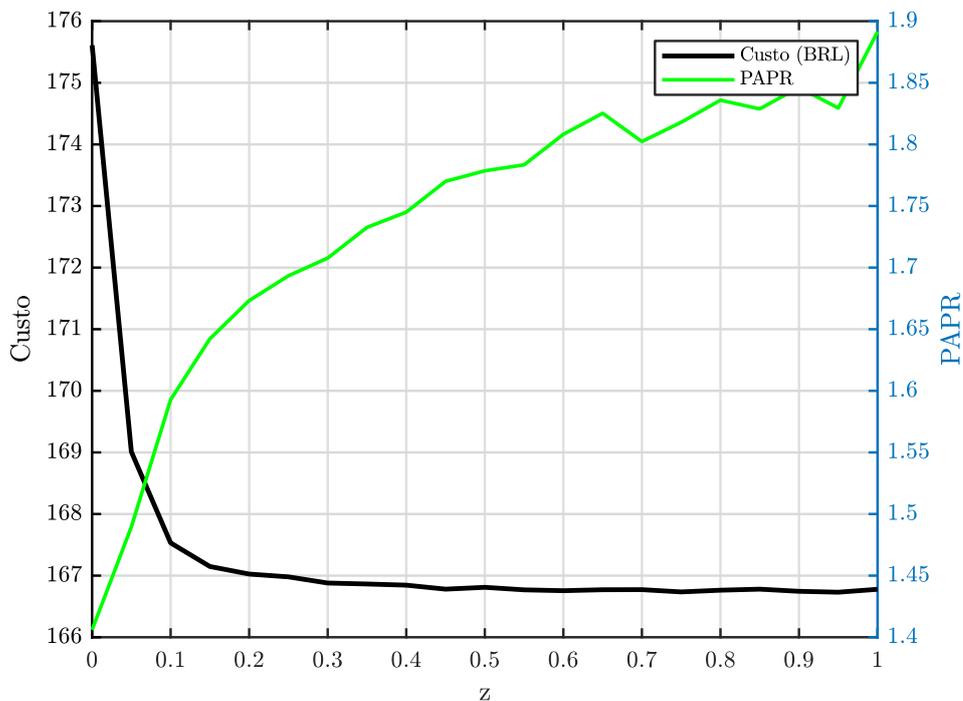
a utilização de 10 cargas que podem ser deslocadas e no segundo cenário com 70 cargas que podem ser deslocadas, sendo que os valores de potência dos equipamentos são considerados conforme Logenthiran, Srinivasan e Shun (2012). Em ambos os cenários, foram realizados as simulações para dois modelos tarifários.

5.1 APLICAÇÃO DE *EPSO* PARA 10 CARGAS

Neste cenário, considera-se a utilização de 10 cargas conforme a A.1 (Apêndice A). A energia consumida pelas cargas é 27.5 kWh. Assim pode-se dizer que a contribuição para a curva de carga deste grupo de cargas representa apenas 10.8%. No âmbito de restrições, todas as cargas devem ser agendadas durante o dia ou noite, não podendo ser agendadas no período da madrugada.

Considerando a modelagem realizada no Capítulo 3, foram realizadas as simulações para o agendamento das cargas considerando a variação de peso z , sendo que $0 \leq z \leq 1$. A Figura 5.2 apresenta os resultado das simulações para esta variação de peso, sendo que nesta simulação considera-se a utilização da tarifa inversamente proporcional à curva de geração fotovoltaica.

Figura 5.2 – Função objetivo para variações de pesos z , considerando 10 Cargas possíveis para o agendamento. Tarifa inversamente proporcional à uma curva de geração fotovoltaica.



Fonte: Elaborada pelo autor

Após, realizaram-se simulações considerando os pontos extremos referentes a fun-

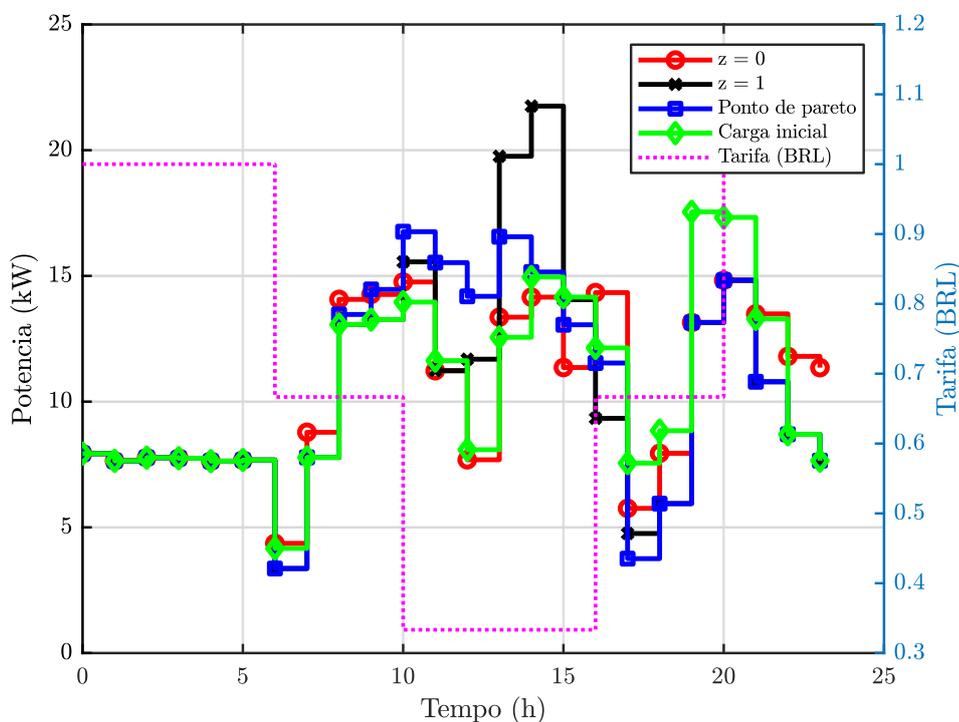
Tabela 5.1 – Resultados obtidos para os agendamentos, considerando a condição inicial sem agendamento, com $z = 0$ (minimização de PAPR), com $z = 1$ (minimização de custo) e para o ponto de pareto.

| Condição | Tarifa inverso solar | |
|-----------------|----------------------|-------|
| | Custo (BRL) | PAPR |
| Sem agendamento | 174.34 | 1.664 |
| $z=0$ (PAPR) | 177.17 | 1.41 |
| $z=1$ (Custo) | 166.83 | 2.06 |
| Pareto | 168.67 | 1.59 |

Fonte: Elaborada pelo autor

ção objetivo e ponto de Pareto. A Figura 5.3 apresenta o resultado das simulações para todos os casos, bem como o caso da situação inicial. Sendo que a Tabela 5.1 apresenta o os resultados obtidos para as métricas em diferentes pesos, considerando cenários de simulações com 10 cargas.

Figura 5.3 – Curvas de agendamento considerando o agendamento de 10 cargas, para $z = 0$ (minimização de custo), $z = 1$ (minimização de PAPR), z no ponto de pareto e na condição inicial antes do agendamento.



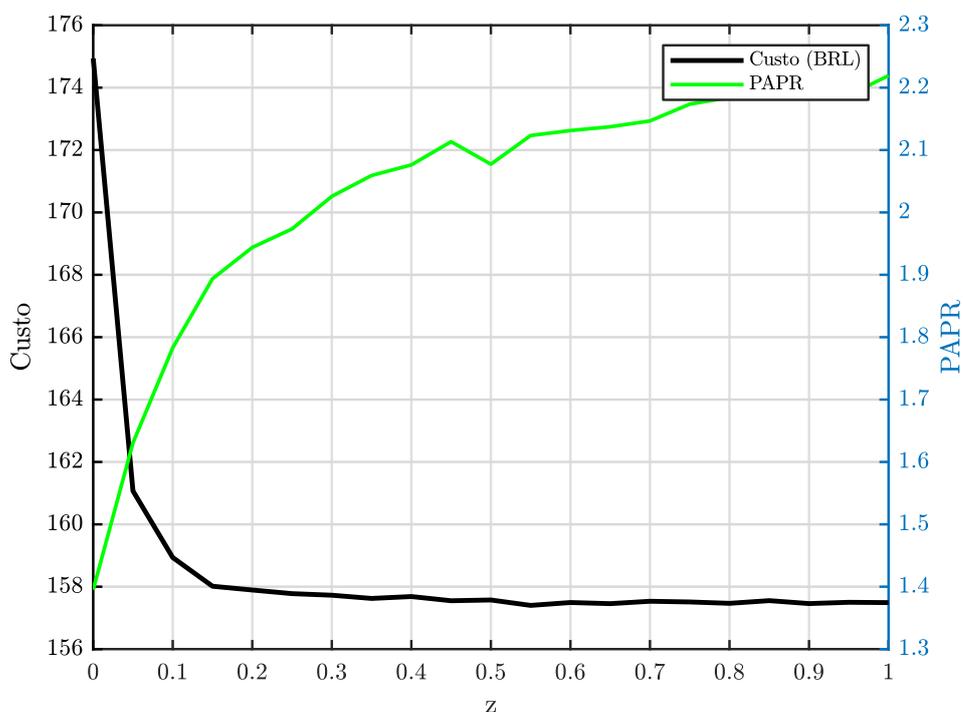
Fonte: Elaborada pelo autor

5.2 APLICAÇÃO DE *EPSO* PARA 70 CARGAS

Neste cenário, considera-se a utilização de 70 cargas deslocáveis, que compõem a curva de carga, conforme a Tabela A.2 (Apêndice A). A energia consumida por essas cargas é 68.25 kWh. Assim, pode-se dizer que a contribuição para a curva de carga deste grupo de cargas representa apenas 26.97%. No âmbito de restrições, todas as cargas devem ser agendadas durante o dia ou noite, conforme realizado no cenário com 10 cargas.

A Figura 5.4 apresenta as respostas obtidas para as métricas de custo e PAPR, considerando uma variação de peso z a um passo de 0.05.

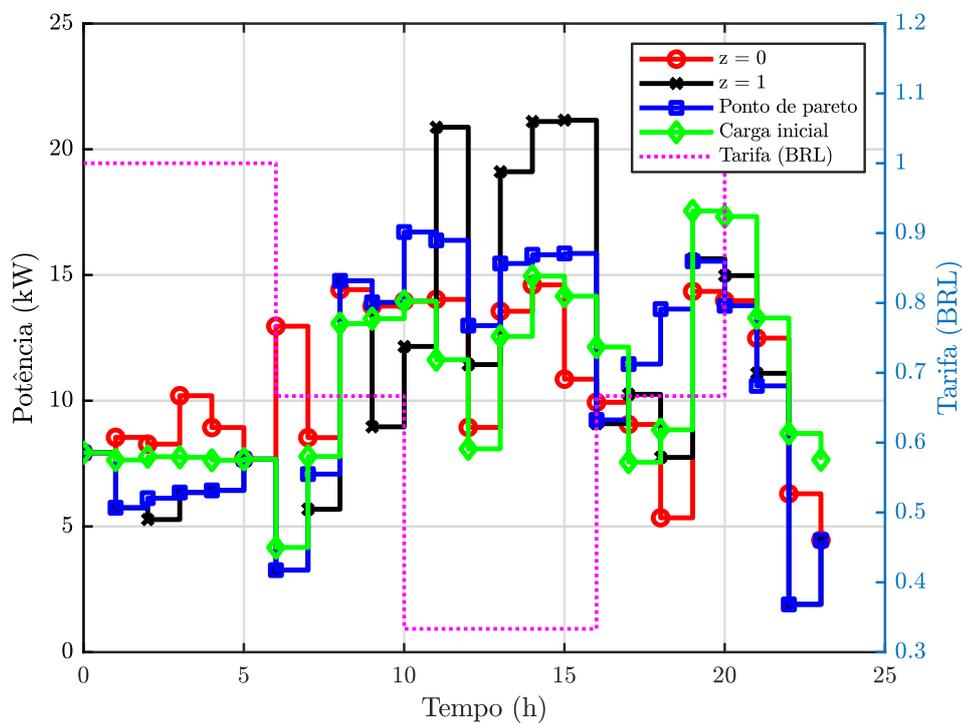
Figura 5.4 – Função objetivo para variações de peso com 70 cargas, considerando tarifa inversa à uma curva de geração fotovoltaica



Fonte: Elaborada pelo autor

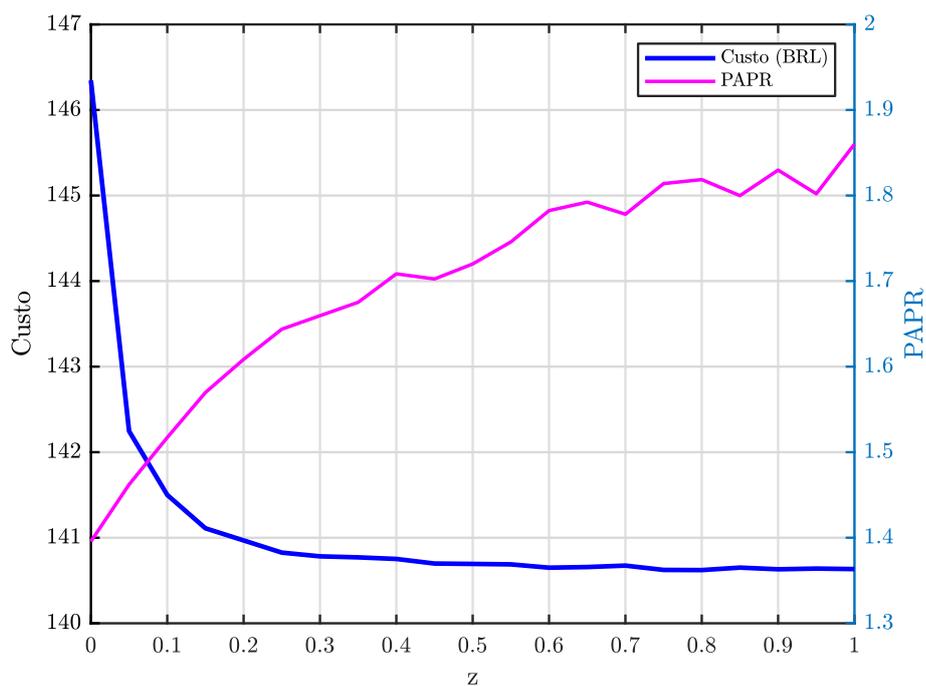
Percebe-se que o ponto de Pareto permanece com um mesmo peso de z quando aplicada a mesma tarifa. Este fato ocorre porque, embora no segundo cenário considere-se um número maior de cargas deslocáveis, o somatório de cargas ao longo do período é o mesmo. Entretanto, embora o ponto permaneça com o mesmo peso, percebe-se que os valores de custo e PAPR neste ponto são diferentes. Isto ocorre devido à maior quantidade de cargas disponíveis para serem alocadas, facilitando a obtenção de melhores resultados para o agendamento.

Figura 5.5 – Curvas de agendamento considerando o agendamento de 70 cargas, para $z = 0$ (minimização de custo), $z = 1$ (minimização de PAPR), z no ponto de pareto e na condição inicial antes do agendamento.



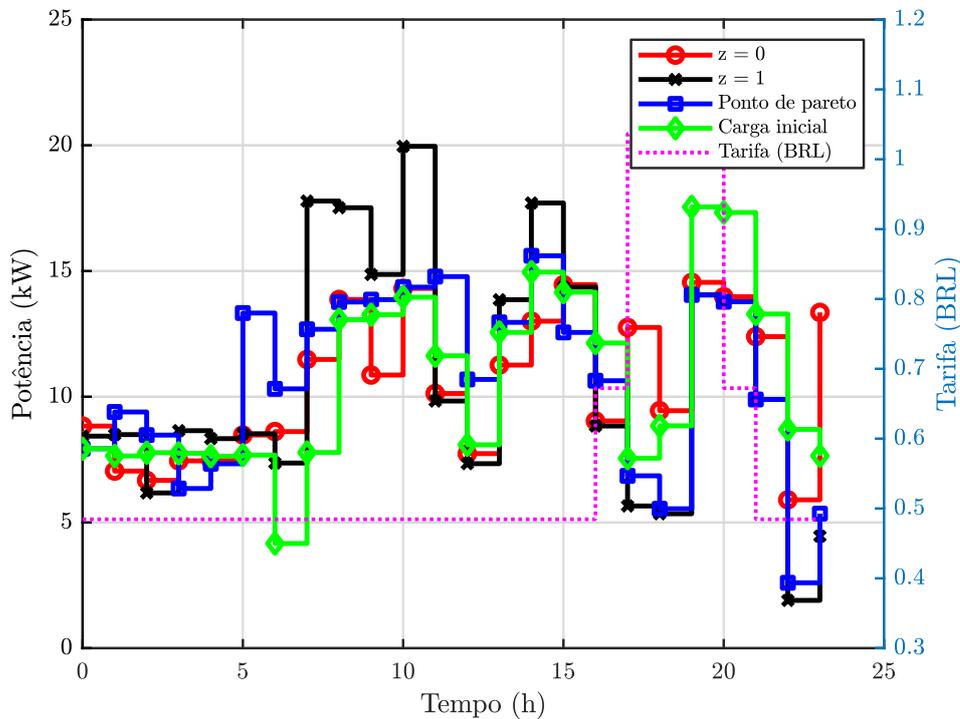
Fonte: Elaborada pelo autor

Figura 5.6 – Função objetivo para variações de pesos e 70 Cargas. Tarifa branca.



Fonte: Elaborada pelo autor

Figura 5.7 – Curvas de agendamento considerando o agendamento de 70 cargas, para $z = 0$ (minimização de custo), $z = 1$ (minimização de PAPR), z no ponto de pareto e na condição inicial antes do agendamento.



Fonte: Elaborada pelo autor

A Tabela 5.2 apresenta os resultados obtidos para as métricas de custo e PAPR, para diferentes valores de peso z , considerando cenário de simulações com 70 cargas e a utilizando de dois modelos tarifários (Inversa a curva fotovoltaica e tarifa branca).

Tabela 5.2 – Resultados obtidos para os agendamentos, considerando a condição inicial sem agendamento, com $z = 0$ objetivo de minimização de PAPR, com $z = 1$ objetivo de minimização de custo e para o ponto de Pareto onde apresenta o ótimo para as duas grandezas.

| Condição | Tarifa inverso solar | | Tarifa Branca | |
|-----------------|----------------------|-------|---------------|-------|
| | Custo (BRL) | PAPR | Custo (BRL) | PAPR |
| Sem agendamento | 174.34 | 1.664 | 146.9 | 1.664 |
| $z=0$ (PAPR) | 173 | 1.39 | 147.24 | 1.38 |
| Pareto | 161.8 | 1.58 | 141.81 | 1.48 |
| $z=1$ (Custo) | 157.38 | 2.01 | 139.7 | 1.89 |

Fonte: Elaborada pelo autor

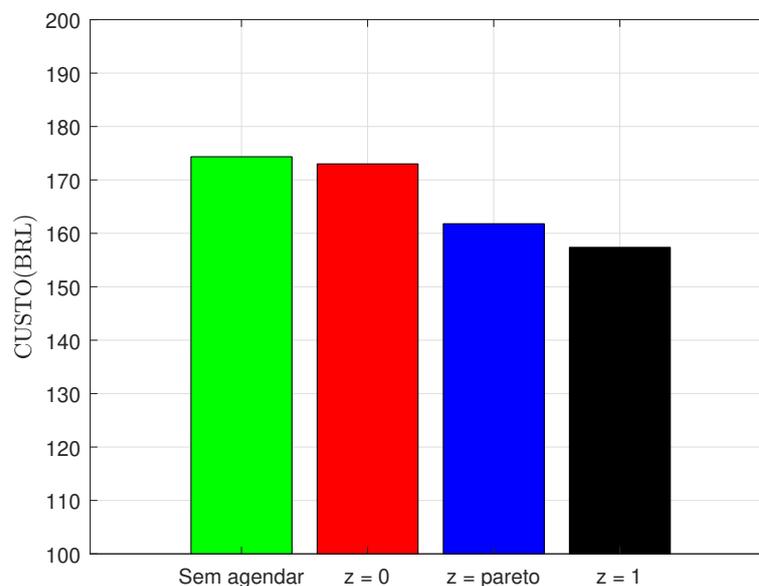
5.3 ANÁLISE RESULTADOS REFERENTE AO EPSO APLICADO A AO ESTUDO DE CASO

Considerando as curvas de carga apresentadas referente as simulações do estudo de caso a seguir serão analisados os resultados obtidos referente as métricas de custo e PAPR.

5.3.1 Análise considerando tarifa inversa a uma curva fotovoltaica

As Figuras 5.8 e 5.9 apresentam os resultados comparativo entre a condição inicial e as os 3 diferentes pesos aplicados ($z = 0$, $z = \text{Pareto}$ e $z = 1$), conforme curva de carga apresentada na Figura 5.5, considerando o cenário com 70 cargas para o cenário com uma tarifa com preços inversamente proporcionais à uma curva de geração fotovoltaica.

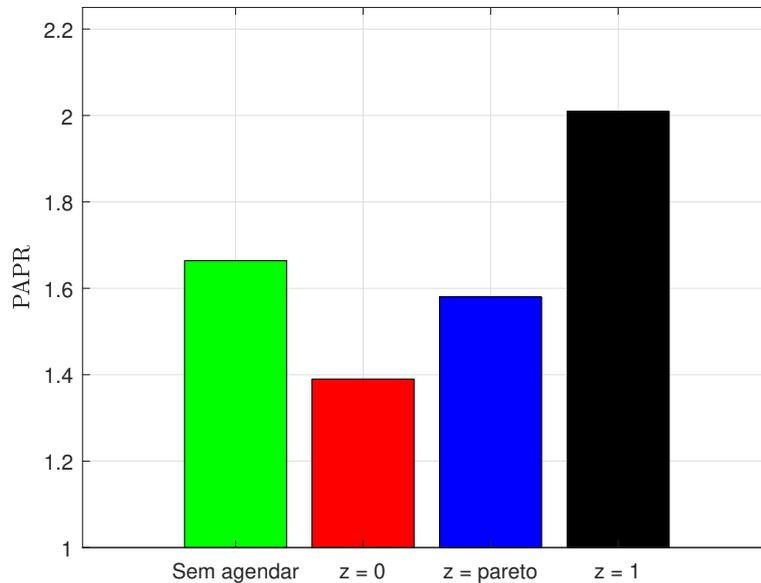
Figura 5.8 – Comparativo entre os resultados obtidos referentes ao custo para o método *EPSO*. Considerando os pesos, $z = 0$ somente a métrica de PAPR, $z = 1$ somente a métrica de custo e $z = \text{Pareto}$ apresenta o ponto de equilíbrio entre as duas métricas



Fonte: Elaborada pelo autor

Através dos resultados obtidos nas Figuras 5.8 e 5.9, considerando os pesos adotados, percebe-se quando utilizado o peso $z = 0$, que busca a redução do PAPR, sem levar em consideração a métrica de custo, obteve-se um a redução de 16.47% no PAPR em relação à situação sem agendamento, sendo que nesta condição mesmo assim o custo reduziu em 0.7%. Isto ocorre pois, na tentativa de reduzir o pico, algumas cargas acabaram deslocando-se para momentos de menor custo tarifário. Entretanto, em outro cenário, poderia ocorrer também o aumento do preço, dependendo da condição inicial.

Figura 5.9 – Comparativo entre os resultados obtidos referentes ao PAPR para o método *EPSO*. Considerando os pesos, $z = 0$ considera somente a métrica de PAPR, $z = 1$ considera somente a métrica de custo e $z = \text{Pareto}$ apresenta o ponto de equilíbrio entre as duas métricas.



Fonte: Elaborada pelo autor

Para o peso $z = 1$, que busca a redução de custo sem levar em consideração a métrica de PAPR, obteve-se uma redução de custo em 9.73% em relação a situação sem agendamento, enquanto que o PAPR aumentou em 20.79%.

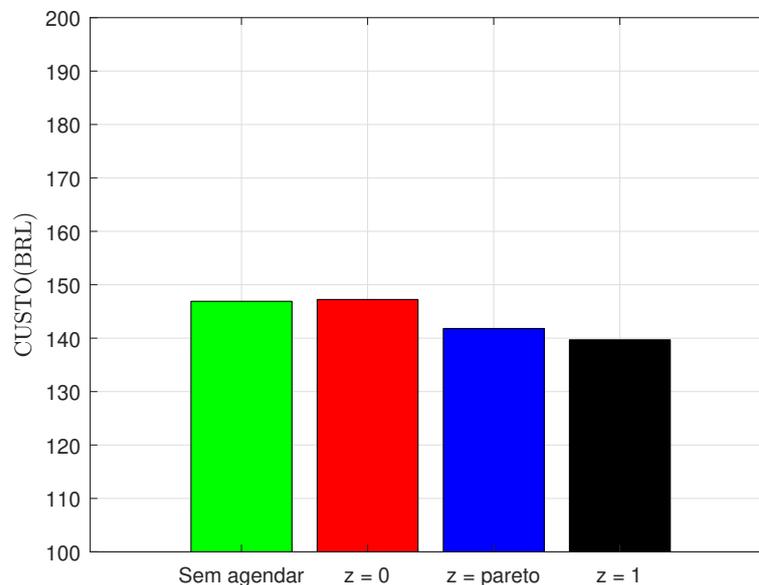
Quando considerado o ponto de Pareto, que representa o ponto onde as duas métricas obtêm o melhor valor sem uma prejudicar a outra, os resultados de custo foi uma redução em 7.09% e do PAPR uma redução de 5.05% em relação a condição sem agendamento.

5.3.2 Análise considerando tarifa branca

As Figuras 5.10 e 5.11 apresentam os resultados comparativo entre a condição inicial e os 3 diferentes pesos aplicados ($z = 0$, $z = \text{Pareto}$ e $z = 1$) conforme curva de carga apresentada na Figura 5.7, considerando o cenário com 70 cargas com modelo de tarifa branca.

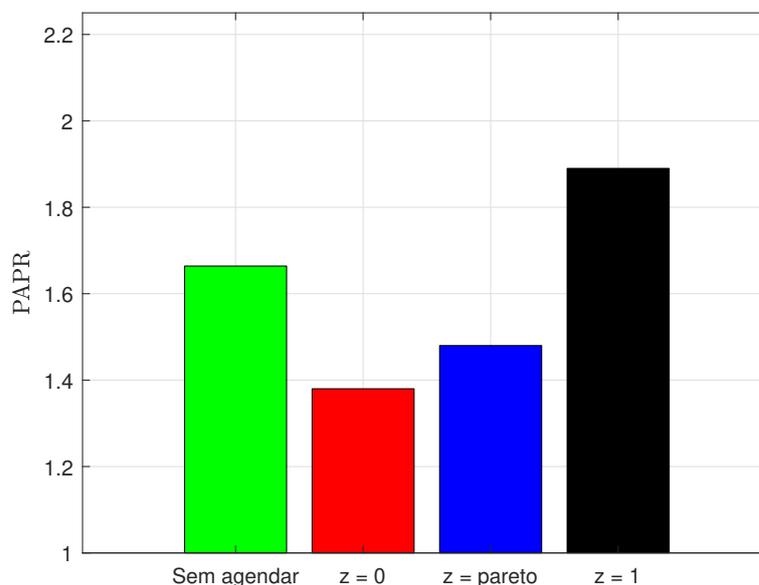
De acordo com os resultados apresentados nas Figuras 5.10 e 5.11, e comparando com a situação sem agendamento para o peso $z = 0$, tem-se um acréscimo no custo em 0.23% e uma redução do PAPR em 17.07%. Para $z = 1$ obteve-se uma redução no custo 4.9% enquanto que o PAPR teve um acréscimo de 13.58%. No ponto de Pareto, tem-se uma redução no custo em 3.46% e o PAPR uma redução de 11.84%.

Figura 5.10 – Comparativo entre os resultados obtidos referentes ao custo para o método *EPSO*. Considerando os pesos, $z = 0$ considera somente a métrica de PAPR, $z = 1$ considera somente a métrica de custo e $z = \text{Pareto}$ apresenta o ponto de equilíbrio entre as duas métricas.



Fonte: Elaborada pelo autor

Figura 5.11 – Comparativo entre os resultados obtidos referentes ao PAPR para o método *EPSO*. Considerando os pesos, $z = 0$ somente a métrica de PAPR, $z = 1$ somente a métrica de custo e $z = \text{Pareto}$ apresenta o ponto de equilíbrio entre as duas métricas.



Fonte: Elaborada pelo autor

5.4 RESUMO DO CAPÍTULO

Neste capítulo utilizando o método *EPSO* que obteve melhor, são realizadas simulações para o agendamento de cargas considerando uma curva de carga real. Nesta

situação, considerou-se dois modelos tarifários e cenários com 10 e 70 cargas.

Por fim é apresentada uma análise dos resultados referente às simulações do estudo de caso aplicado a uma curva de carga real para as situações de tarifas variáveis considerando diferentes pesos aplicados a função objetivo.

6 CONCLUSÃO

A utilização de uma proposta de agendamento mostra-se valiosa. Entretanto destaca-se que, para que ocorra a efetividade de ações, requer-se que uma infraestrutura seja implementada e que possibilite um gerenciamento de cargas em redes elétricas inteligentes, destacando principalmente os equipamentos inteligentes (*Smart Appliances*) e a tendência de cada vez mais se difundir à ampliação das *Smart Grids*.

Um fator importante para efetividade do modelo proposto neste trabalho refere-se a aplicação de tarifas variáveis ao longo do dia, essa utilização de modelos tarifários com diversos patamares ou até mesmo variar ao longo da rede, com patamares distintos apresentam um papel decisivo para alterações de comportamentos dos usuários da rede elétrica. Sabe-se que atualmente as discussões sobre modelos tarifários estão em constante discussão no Brasil e com o avanços das redes inteligentes ou das micro redes este tema apresentará enorme relevância.

Destaca-se que as restrições para horário de funcionamento de equipamentos mostrou-se eficiente para aplicação em residências ou grupo de residências e através de suas considerações possibilita ao usuário mantenha um conforto da utilização de seus equipamentos. O principal motivação para uma modelagem que aborde essas restrições aliado a consideração de que os equipamentos podem apresentar duração de funcionamento distintos é ampliar a gama de cargas que possam vir a participar do modelo de agendamento de cargas.

A abordagem que considera a utilização das duas métricas que apresentam características distintas, flexibiliza o modelo no âmbito do cliente, gerenciador do sistema e possibilita apresentar equilíbrio entre os dois, admitindo assim que este modelo possa ser utilizado a diversos tipos de aplicações. Sendo que outros parâmetros podem ser incorporados ao modelo.

Considerando a aplicação de modelo na qual o gerenciador do sistema atua na parametrização de z , pode-se estabelecer relação contratual entre cliente e a concessionária para entregar a programação de algumas das suas cargas e, então, o gerenciador do sistema torna-se responsável pela transmissão de z ao algoritmo implementado. Destaca-se que o valor adotado para o parâmetro z de um cliente é sensível ao quantitativo de cargas envolvidas, que poderão ser definidas através de contrato entre os agentes, e que os limitantes de 0 e 1 podem ser utilizados para estabelecimento de critérios contratuais entre os agentes.

Baseado no resultados obtidos neste trabalho, considera-se que a utilização de métodos heurísticos para o agendamento de cargas pode ser uma solução eficiente e relevante para obter uma solução quase-ótima no agendamento de consumo de dispositivos, possibilitando assim, quando implementado, que sejam obtidos resultados satisfatórios na

redução de custo e no pico de potência sobre a rede. Salienta-se que matematicamente existem muitos métodos de otimização com possibilidades de serem implementados, para a modelagem deste problema sendo que cada um destes apresentam características e considerações típicas de cada um dos métodos.

Destaca-se que o método de otimização heurística *EPSO* por ser um método evolutivo auto-adaptativo, mostra-se o melhor em custo-benefício nos aspectos de resultado das métricas, tempo de convergência e escalabilidade para a modelagem proposta neste trabalho. Neste aspecto destaca-se ainda que a vantagem da utilização do *EPSO* é que o mesmo não apresenta muitos parâmetros externos a serem definidos por um usuário e podem ser decisivos na resposta obtida, assim torna-se este método mais robusto para a sua implementação.

Portanto conclui-se através desta dissertação que a utilização de métodos de otimização aplicando a técnica de deslocamento para o agendamento de cargas é algo relevante para permitir a integração dos consumidores de energia elétrica às novas formas de relacionamento que podem estar disponíveis a partir dos avanços técnicos que são vislumbrados no futuro eminente das redes elétricas.

6.1 TRABALHOS FUTUROS

Como perspectiva de trabalhos futuros a serem realizados com base nesta dissertação tem-se:

1. Desenvolvimento de um modelo de previsão de carga que possibilite prever o comportamento das cargas para o dia seguinte, associado em aspectos ambientais.
2. Incorporar à modelagem abordada outras métricas que possam ser relevante junto a função objetivo.
3. Utilização do modelo considerando uma discretização menor de tempo, que possibilite a utilização de outras cargas o que ampliará ainda mais o espaço de busca.
4. Implementação de outros métodos de otimização na tentativa de encontrar respostas superiores as respostas obtidas pelo *EPSO*, por exemplo soluções baseadas em aprendizagem de máquina com redes neurais (ou outras técnicas)
5. Testar o algoritmo em adaptações de tempo real, quando cargas não previstas são inseridas no sistema, associar ao modelo a possibilidade de não agendamento de determinadas cargas.
6. Modelar a carga não-controlável usando uma análise estatística ou alguma outra forma de previsão.

7. Modelar o sistema levando em consideração a presença de sistema de geração fotovoltaico, sistemas de armazenamento e veículo elétrico

6.2 PUBLICAÇÕES REFERENTES AO TEMA DO TRABALHO

Durante a realização desta dissertação foram realizadas as seguintes publicações.

- BERTINETI, D. P. ; SILVA, B. F. ; CANHA, L. N. ; MEDEIROS, A. P. ; AZEVEDO, R. M. . **Heuristic Scheduling Algorithm for Load Shift DSM Strategy in Smart Grids and IoT Scenarios**. In: 2019 IEEE PES Innovative Smart Grid Technology Latin America (ISGT LA), 2019, Gramado - RS. 2019 IEEE PES Innovative Smart Grid Technology Latin America (ISGT LA), 2019.
- P. Medeiros, D. P. Bertineti, L. N. Canha and R. M. de Azevedo, "**Monitoramento da carga elétrica residencial aplicado ao gerenciamento de resposta a demanda**," 11th Seminar on Power Electronics and Control (SEPOC), Santa Maria, Brazil, 2018, pp. 1-6.
- A. P. Medeiros, L. N. Canha, D. P. Bertineti and R. M. de Azevedo, "**Event classification in non-intrusive load monitoring using convolutional neural network** ," 2019 IEEE PES Innovative Smart Grid Technology conference Latin America 2019 (ISGTLA), Gramado, Brazil, 2019, pp. 1-6.
- BRIGNOL, W. S. ; CANHA, L. N. ; AZEVEDO, R. M. ; FARIAS, C. M. ; BERTINETI, D. P. ; KNAK NETO, N. . **Commercial technical proposal to enlarge the participation of sources of generation distributed by biogas in the brazilian electrical system..** In: 52nd International Universities Power Engineering Conference - UPEC2017, 2017, Greece. Commercial technical proposal to enlarge the participation of sources of generation distributed by biogas in the brazilian electrical system., 2017.

REFERÊNCIAS BIBLIOGRÁFICAS

ANEEL. **Unidades Consumidoras com Geração Distribuída**: Informações compiladas e mapa. Agência Nacional de Energia Elétrica, 2019. Acesso em 10 out. 2019. Disponível em: <<https://www.aneel.gov.br/>>.

ASSAF, T. et al. Fair and efficient energy consumption scheduling algorithm using tabu search for future smart grids. **IET Generation, Transmission Distribution**, v. 12, n. 3, p. 643–649, 2018.

AZEVEDO, R. M. d. **Impactos operacionais da complementariedade de fontes de geração solar fotovoltaica e a biogás em sistemas de distribuição**. 2017. Dissertação (Mestrado) — Universidade Federal de Santa Maria, 2017.

BERA, S.; GUPTA, P.; MISRA, S. D2s: Dynamic demand scheduling in smart grid using optimal portfolio selection strategy. **IEEE Transactions on Smart Grid**, v. 6, n. 3, p. 1434–1442, May 2015.

CARON, S.; KESIDIS, G. Incentive-based energy consumption scheduling algorithms for the smart grid. In: **2010 First IEEE International Conference on Smart Grid Communications**. [S.l.: s.n.], 2010. p. 391–396.

CARVALHO, É. d. C. R. **Solução de problemas de otimização com restrições usando estratégias de penalização adaptativa e um algoritmo do tipo PSO**. 2014. 148 f. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora (UFJF), Juiz de Fora, 2014.

CHATTERJEE, A.; SIARRY, P. Nonlinear inertia weight variation for dynamic adaptation in particle swarm optimization. **Computers & Operations Research**, v. 33, n. 3, p. 859 – 871, 2006. ISSN 0305-0548. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0305054804002023>>.

DENHOLM, P. et al. **Overgeneration from solar energy in California. A field guide to the duck chart**. [S.l.], 2015.

DU NING LU, H. Z. P. **Demand Response in Smart Grids**. [S.l.]: Springer, 2019. ISBN 978-3-030-19768-1, 978-3-030-19769-8.

EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. In: **MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science**. [S.l.: s.n.], 1995. p. 39–43.

EBERHART, R.; SIMPSON, P.; DOBBINS, R. **Computational intelligence PC tools**. [S.l.]: Academic Press Professional, Inc., 1996.

ENGELBRECHT, A. P. **Computational Intelligence. An Introduction**. 2. ed. [S.l.]: Wiley, 2007. ISBN 9780470035610,0470035617.

GELLINGS, C. W. The concept of demand-side management for electric utilities. **Proceedings of the IEEE**, v. 73, n. 10, p. 1468–1470, Oct 1985. ISSN 0018-9219.

HAIDER, H. T.; SEE, O. H.; ELMENREICH, W. A review of residential demand response of smart grid. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 59, p. 166–178, 2016.

JAIN, P. L. C. et al. **Advances in Evolutionary Computing for System Design**. 1. ed. [S.l.]: Springer-Verlag Berlin Heidelberg, 2007. (Studies in Computational Intelligence 66). ISBN 978-3-540-72376-9,978-3-540-72377-6.

JAVAID, N. et al. An intelligent load management system with renewable energy integration for smart homes. **IEEE Access**, v. 5, p. 13587–13600, 2017.

KHALID, A. et al. Towards dynamic coordination among home appliances using multi-objective energy optimization for demand side management in smart buildings. **IEEE Access**, v. 6, p. 19509–19529, 2018. ISSN 2169-3536.

LOGENTHIRAN, T.; SRINIVASAN, D.; SHUN, T. Z. Demand side management in smart grid using heuristic optimization. **IEEE Transactions on Smart Grid**, v. 3, n. 3, p. 1244–1252, Sep. 2012.

MIRANDA, V.; FONSECA, N. Epso - best-of-two-worlds meta-heuristic applied to power system problems. In: **Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02 (Cat. No.02TH8600)**. [S.l.: s.n.], 2002. v. 2, p. 1080–1085 vol.2.

_____. Epso-evolutionary particle swarm optimization, a new algorithm with applications in power systems. In: **IEEE/PES Transmission and Distribution Conference and Exhibition**. [S.l.: s.n.], 2002. v. 2, p. 745–750 vol.2.

NIKZAD, M.; MOZAFARI, B. Reliability assessment of incentive-and priced-based demand response programs in restructured power systems. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 56, p. 83–96, 2014.

RATNAWEERA, A. Particle swarm optimization with self-adaptive acceleration coefficients. In: **Proc. Int'l Conf. Fuzzy Syst. & Knowledge Discovery (FSKD 2002), Singapore, Nov.** [S.l.: s.n.], 2002. v. 1, p. 264–268.

RATNAWEERA, A.; HALGAMUGE, S. K.; WATSON, H. C. Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients. **IEEE Transactions on evolutionary computation**, IEEE, v. 8, n. 3, p. 240–255, 2004.

SHI, Y.; EBERHART, R. A modified particle swarm optimizer. In: **1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98TH8360)**. [S.l.: s.n.], 1998. p. 69–73.

SIEBERT, L. et al. Gerenciamento pelo lado da demanda em redes inteligentes utilizando algoritmos genéticos. **IV SBSE–Simpósio Brasileiro de Sistemas Elétricos**, 2012.

TALBI, E.-G. **Metaheuristics: from design to implementation**. New. [S.l.]: Wiley, 2009. (Wiley Series on Parallel and Distributed Computing). ISBN 9780470278581,0470278587.

TORRITI, J. Price-based demand side management: Assessing the impacts of time-of-use tariffs on residential electricity demand and peak shifting in northern italy. **Energy**, Elsevier, v. 44, n. 1, p. 576–583, 2012.

TUSHAR, M. H. K.; ZEINEDDINE, A. W.; ASSI, C. Demand-side management by regulating charging and discharging of the ev, ess, and utilizing renewable energy. **IEEE Transactions on Industrial Informatics**, v. 14, n. 1, p. 117–126, Jan 2018.

VALLE, Y. D. et al. Particle swarm optimization: Basic concepts, variants and applications in power systems. **IEEE Transactions on Evolutionary Computation**, v. 12, n. 2, p. 171–195, April 2008.

ZHOU, B. et al. Smart home energy management systems: Concept, configurations, and scheduling strategies. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 61, p. 30–40, 2016.

APÊNDICE A – TABELAS DE CARGAS UTILIZADA NAS SIMULAÇÕES

A.1 – CENÁRIO COM 10 CARGAS

Tabela A.1 – Cargas consideradas para o agendamento no estudo de caso considerando uma curva de carga real

| Carga | Potência P_i | L_i | $m_{1,(i)}^{\min}$ | $m_{1,(i)}^{\max}$ |
|----------|----------------|-------|--------------------|--------------------|
| Carga 1 | 1000 | 1 | 16 | 24 |
| Carga 2 | 1500 | 2 | 12 | 23 |
| Carga 3 | 2000 | 3 | 10 | 20 |
| Carga 4 | 800 | 4 | 7 | 18 |
| Carga 5 | 1500 | 1 | 12 | 20 |
| Carga 6 | 400 | 2 | 6 | 24 |
| Carga 7 | 1500 | 3 | 6 | 24 |
| Carga 8 | 1000 | 4 | 6 | 24 |
| Carga 9 | 800 | 1 | 6 | 24 |
| Carga 10 | 1200 | 2 | 6 | 24 |

Fonte: Elaborada pelo autor

A.2 – CENÁRIO COM 70 CARGAS

Tabela A.2 – Grupo de cargas para simulações.

| Início da tabela | | | | |
|------------------|----------------|-------|--------------------|--------------------|
| Carga | Potência P_i | L_i | $m_{1,(i)}^{\min}$ | $m_{1,(i)}^{\max}$ |
| Carga 1 | 1200 | 1 | 16 | 24 |
| Carga 2 | 700 | 1 | 12 | 23 |
| Carga 3 | 500 | 2 | 10 | 20 |
| Carga 4 | 1300 | 1 | 7 | 18 |
| Carga 5 | 1000 | 1 | 12 | 20 |
| Carga 6 | 400 | 1 | 6 | 24 |
| Carga 7 | 200 | 3 | 6 | 24 |
| Carga 8 | 2000 | 1 | 6 | 24 |
| Carga 9 | 900 | 1 | 6 | 24 |
| Carga 10 | 850 | 1 | 6 | 24 |

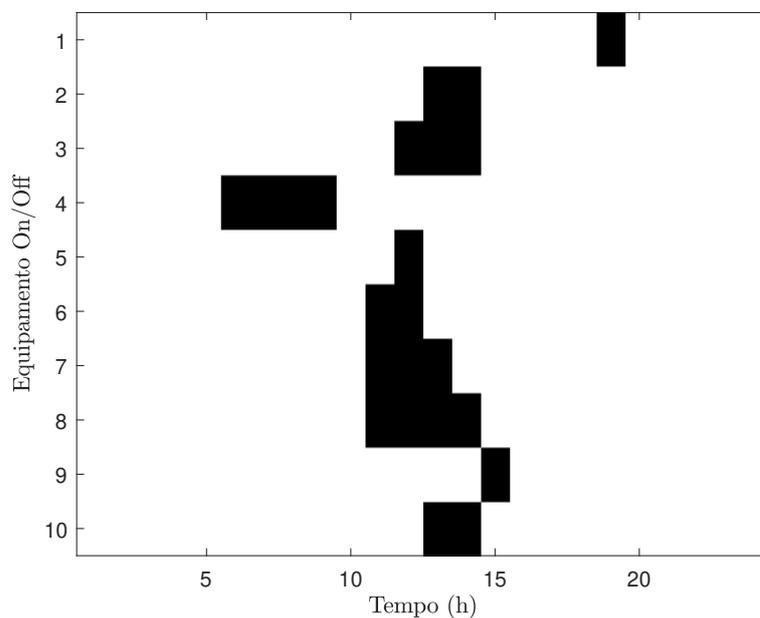
| Continuação da A.2 | | | | |
|--------------------|------|---|----|----|
| Carga 11 | 1500 | 1 | 16 | 24 |
| Carga 12 | 300 | 1 | 12 | 23 |
| Carga 13 | 1100 | 1 | 10 | 20 |
| Carga 14 | 800 | 1 | 7 | 18 |
| Carga 15 | 1200 | 1 | 16 | 24 |
| Carga 16 | 700 | 1 | 12 | 23 |
| Carga 17 | 500 | 2 | 10 | 20 |
| Carga 18 | 1300 | 1 | 7 | 18 |
| Carga 19 | 1000 | 1 | 12 | 20 |
| Carga 20 | 400 | 1 | 6 | 24 |
| Carga 21 | 200 | 3 | 6 | 24 |
| Carga 22 | 2000 | 1 | 6 | 24 |
| Carga 23 | 900 | 1 | 6 | 24 |
| Carga 24 | 850 | 1 | 6 | 24 |
| Carga 25 | 1500 | 1 | 16 | 24 |
| Carga 26 | 300 | 1 | 12 | 23 |
| Carga 27 | 1100 | 1 | 10 | 20 |
| Carga 28 | 800 | 1 | 7 | 18 |
| Carga 29 | 1200 | 1 | 16 | 24 |
| Carga 30 | 700 | 1 | 12 | 23 |
| Carga 31 | 500 | 2 | 10 | 20 |
| Carga 32 | 1300 | 1 | 7 | 18 |
| Carga 33 | 1000 | 1 | 12 | 20 |
| Carga 34 | 400 | 1 | 6 | 24 |
| Carga 35 | 200 | 3 | 6 | 24 |
| Carga 36 | 2000 | 1 | 7 | 24 |
| Carga 37 | 900 | 1 | 7 | 24 |
| Carga 38 | 850 | 1 | 7 | 24 |
| Carga 39 | 1500 | 1 | 7 | 24 |
| Carga 40 | 300 | 1 | 7 | 23 |
| Carga 41 | 1100 | 1 | 7 | 20 |
| Carga 42 | 800 | 1 | 7 | 18 |
| Carga 43 | 1200 | 1 | 7 | 24 |
| Carga 44 | 700 | 1 | 7 | 23 |
| Carga 45 | 500 | 2 | 7 | 20 |
| Carga 46 | 1300 | 1 | 7 | 18 |
| Carga 47 | 1000 | 1 | 7 | 20 |
| Carga 48 | 400 | 1 | 7 | 24 |

| Continuação da A.2 | | | | |
|--------------------|------|---|---|----|
| Carga 49 | 200 | 3 | 7 | 24 |
| Carga 50 | 2000 | 1 | 7 | 24 |
| Carga 51 | 900 | 1 | 1 | 24 |
| Carga 52 | 850 | 1 | 1 | 24 |
| Carga 53 | 1500 | 1 | 1 | 24 |
| Carga 54 | 300 | 1 | 1 | 23 |
| Carga 55 | 1100 | 1 | 1 | 20 |
| Carga 56 | 800 | 1 | 1 | 18 |
| Carga 57 | 1200 | 1 | 1 | 24 |
| Carga 58 | 700 | 1 | 1 | 23 |
| Carga 59 | 500 | 2 | 1 | 20 |
| Carga 60 | 1300 | 1 | 1 | 18 |
| Carga 61 | 1000 | 1 | 1 | 20 |
| Carga 62 | 400 | 1 | 1 | 24 |
| Carga 63 | 200 | 3 | 1 | 24 |
| Carga 64 | 2000 | 1 | 1 | 24 |
| Carga 65 | 900 | 1 | 1 | 24 |
| Carga 66 | 850 | 1 | 1 | 24 |
| Carga 67 | 1500 | 1 | 1 | 24 |
| Carga 68 | 300 | 1 | 1 | 23 |
| Carga 69 | 1100 | 1 | 1 | 20 |
| Carga 70 | 800 | 1 | 1 | 18 |

APÊNDICE B – INSTANTES DE TEMPO ONDE AS CARGAS FORAM AGENDADAS PARA CADA UM DOS CENÁRIOS

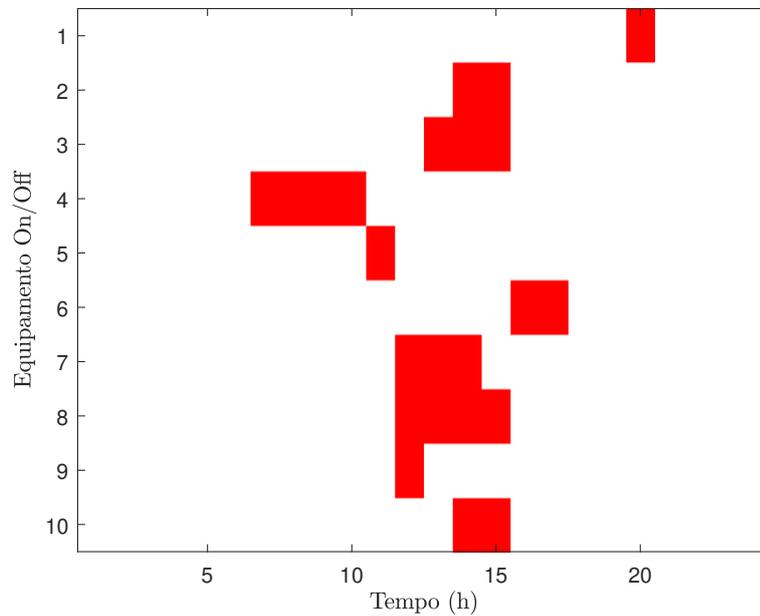
B.1 – COMPARATIVO ENTRE OS MÉTODOS

Figura B.1 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 10 cargas aplicando o método deslocamentos aleatórios com solução única no estilo *Greedy Search*



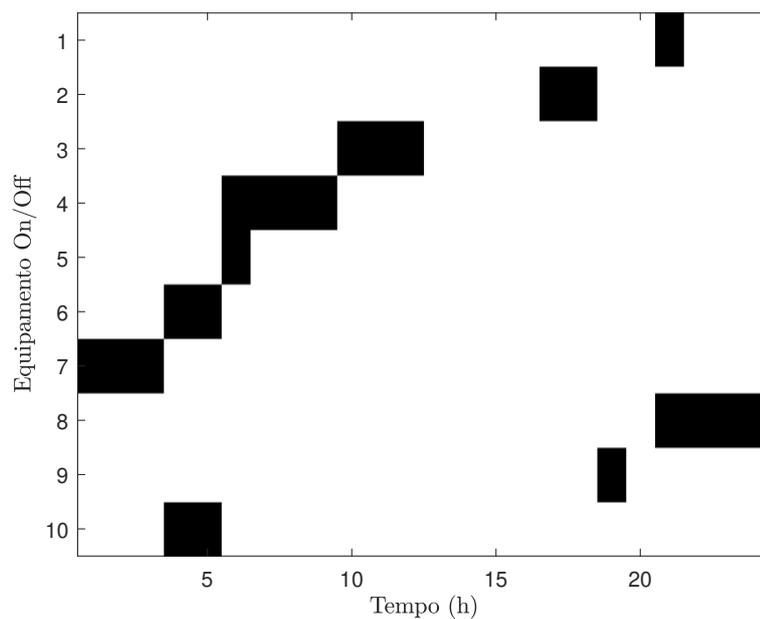
Fonte: Elaborada pelo autor

Figura B.2 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo).
Cenário com 10 cargas aplicando PSO



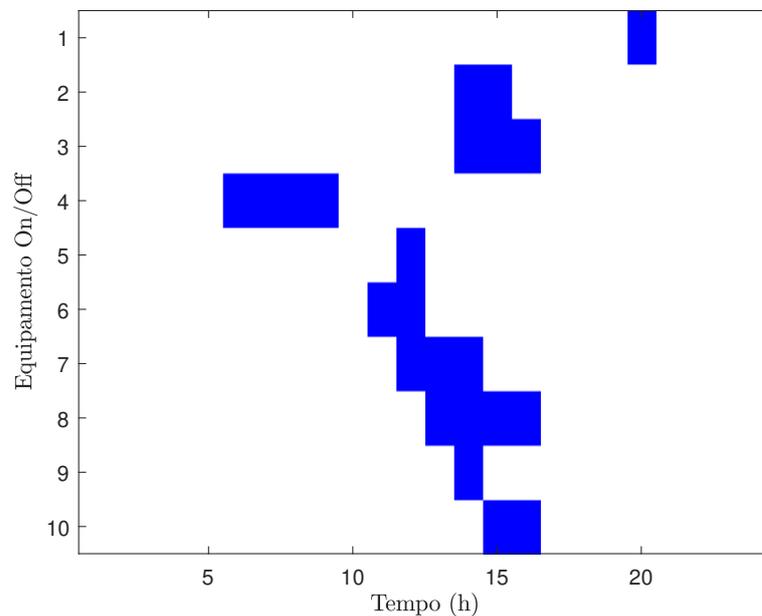
Fonte: Elaborada pelo autor

Figura B.4 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR).
Cenário com 10 cargas aplicando o método deslocamentos aleatórios com solução única
no estilo *Greedy Search*



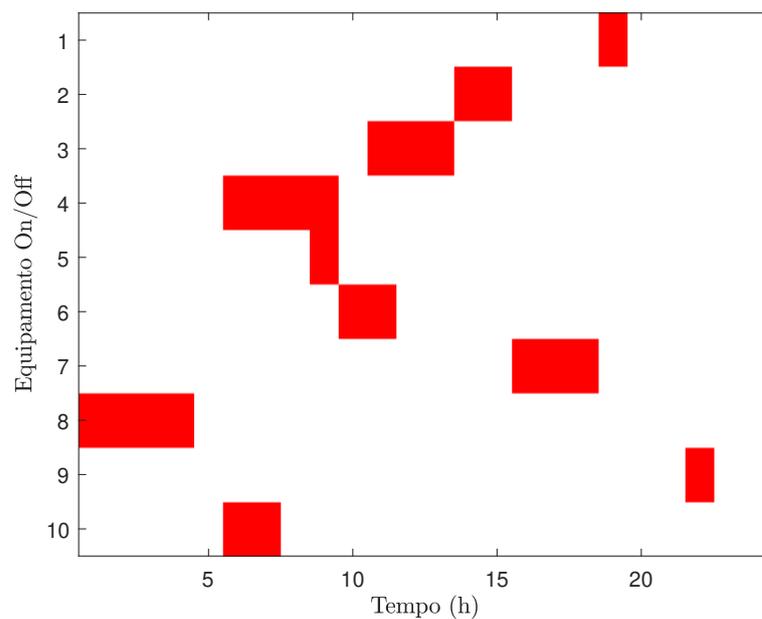
Fonte: Elaborada pelo autor

Figura B.3 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo).
 Cenário com 10 cargas aplicando EPSO



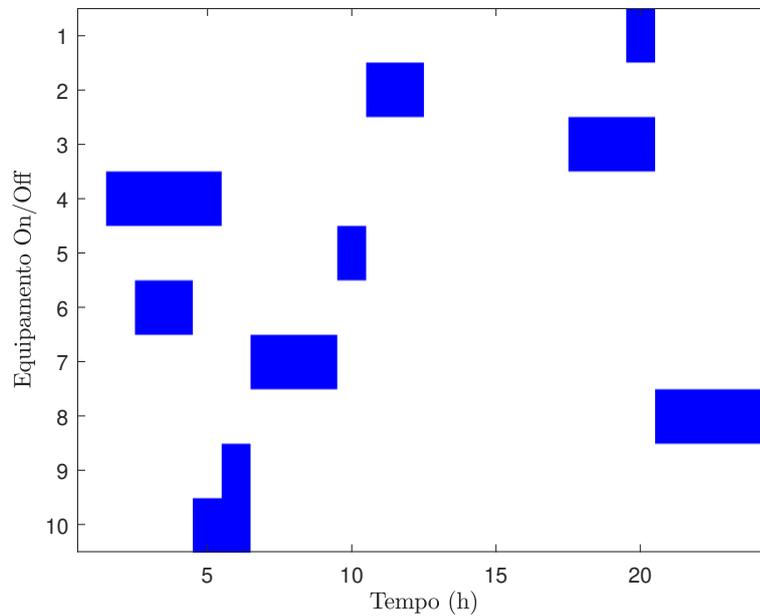
Fonte: Elaborada pelo autor

Figura B.5 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR).
 Cenário com 10 cargas aplicando PSO



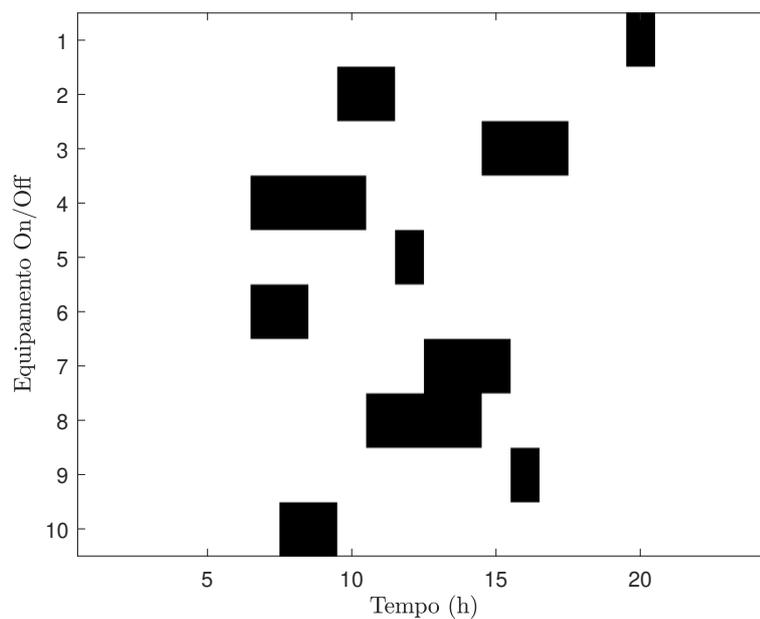
Fonte: Elaborada pelo autor

Figura B.6 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR).
Cenário com 10 cargas aplicando EPSO



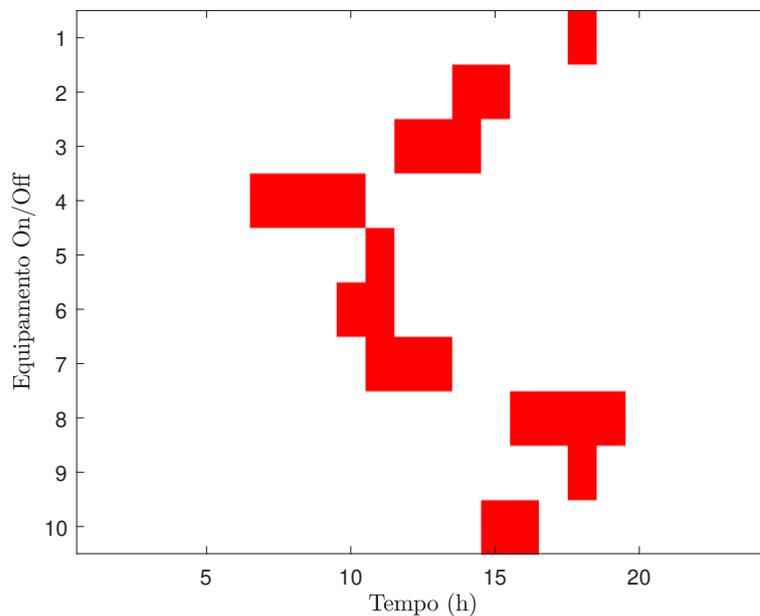
Fonte: Elaborada pelo autor

Figura B.7 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 10 cargas aplicando o método deslocamentos aleatórios com solução única no estilo *Greedy Search*



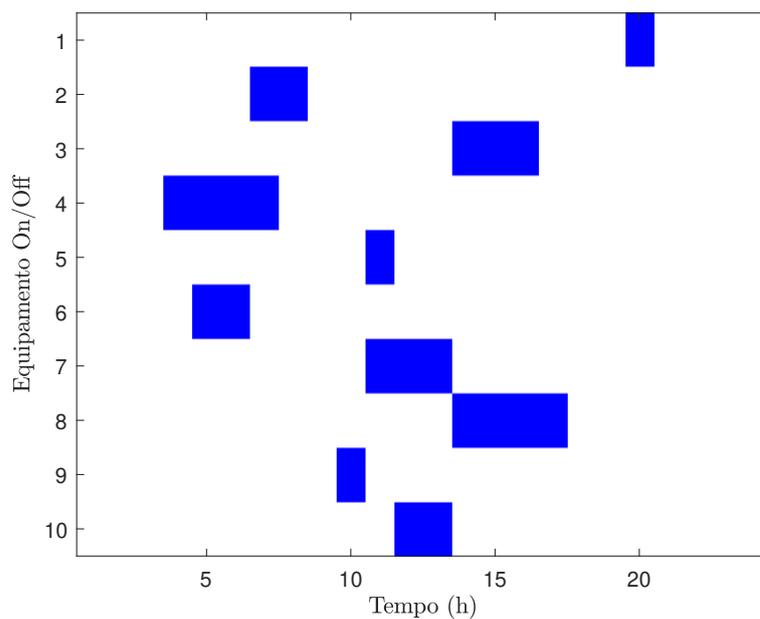
Fonte: Elaborada pelo autor

Figura B.8 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 10 cargas aplicando PSO



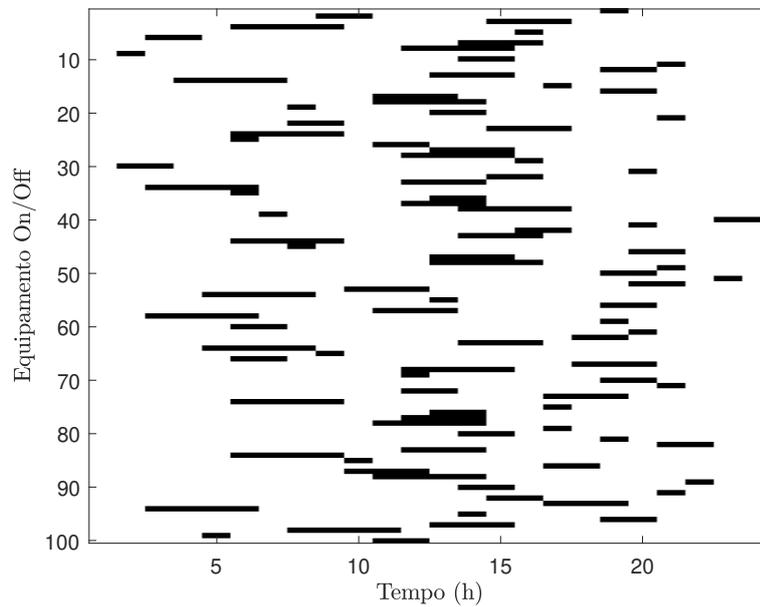
Fonte: Elaborada pelo autor

Figura B.9 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 10 cargas aplicando EPSO



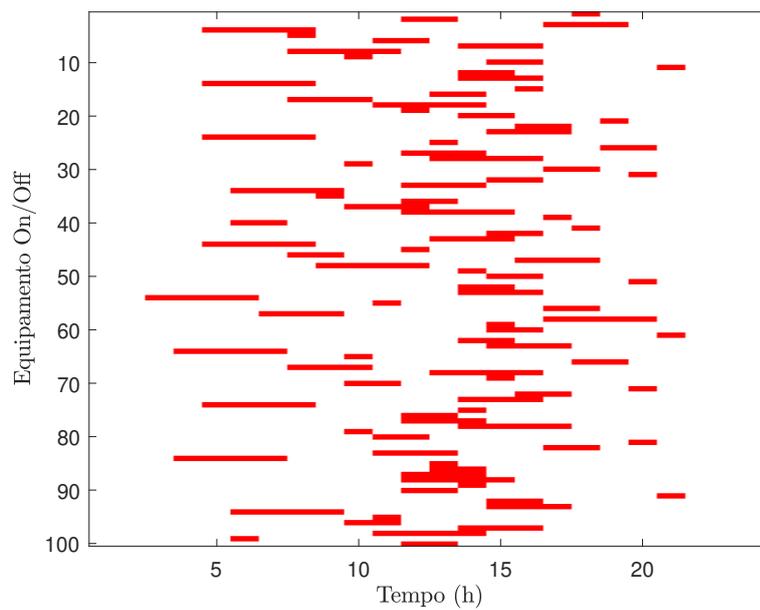
Fonte: Elaborada pelo autor

Figura B.10 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 100 cargas aplicando o método deslocamentos aleatórios com solução única no estilo *Greedy Search*



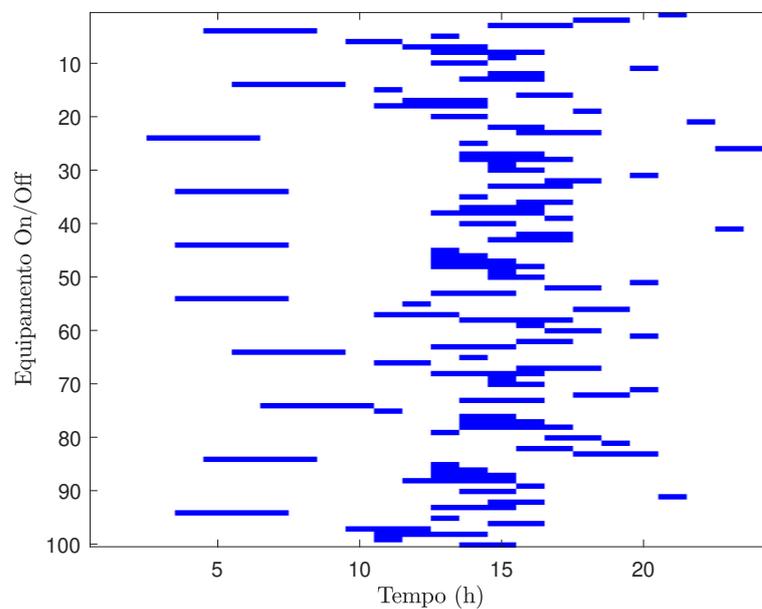
Fonte: Elaborada pelo autor

Figura B.11 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo). Cenário com 100 cargas aplicando PSO



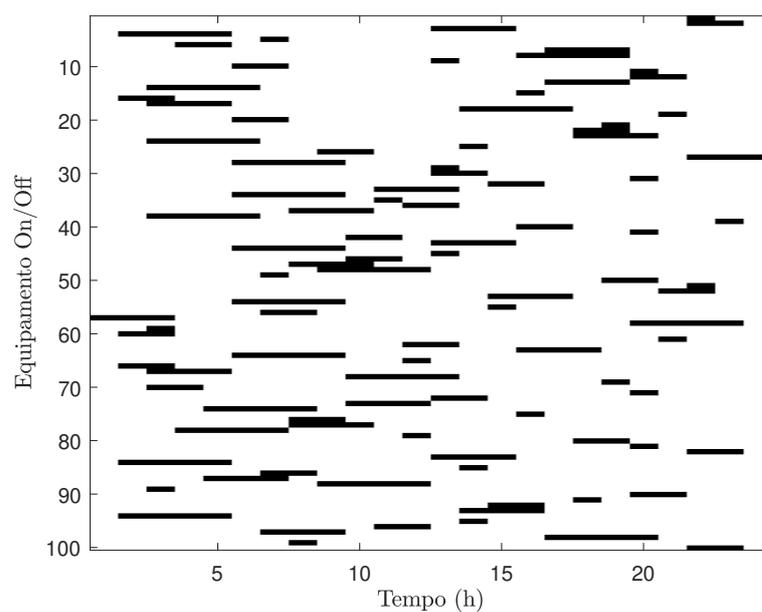
Fonte: Elaborada pelo autor

Figura B.12 – Instante de agendamento de cargas para $z = 1$ (Somente métrica de custo).
Genário com 100 cargas aplicando EPSO



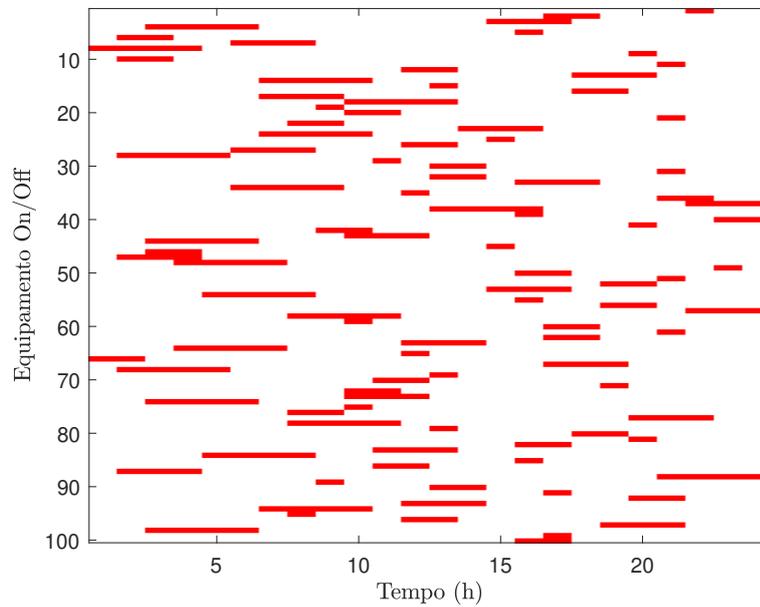
Fonte: Elaborada pelo autor

Figura B.13 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR).
Genário com 100 cargas aplicando o método deslocamentos aleatórios com solução única
no estilo *Greedy Search*



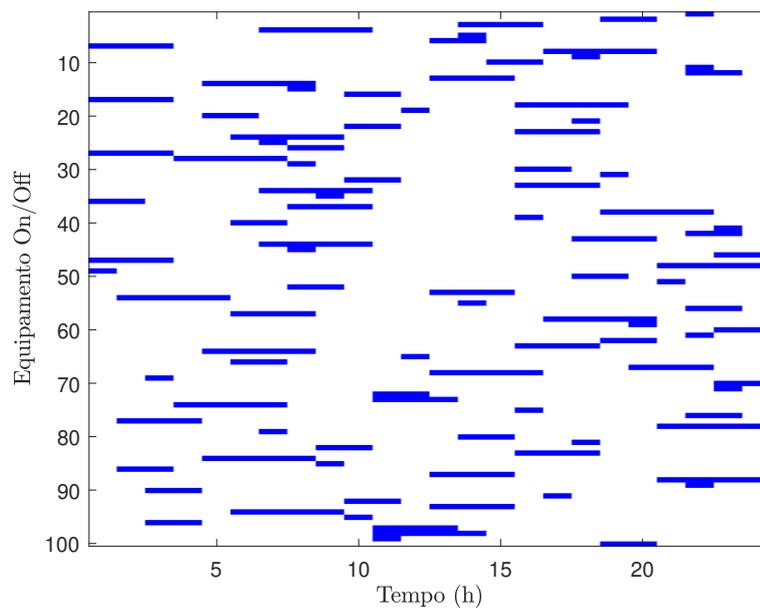
Fonte: Elaborada pelo autor

Figura B.14 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR).
Cenário com 100 cargas aplicando PSO



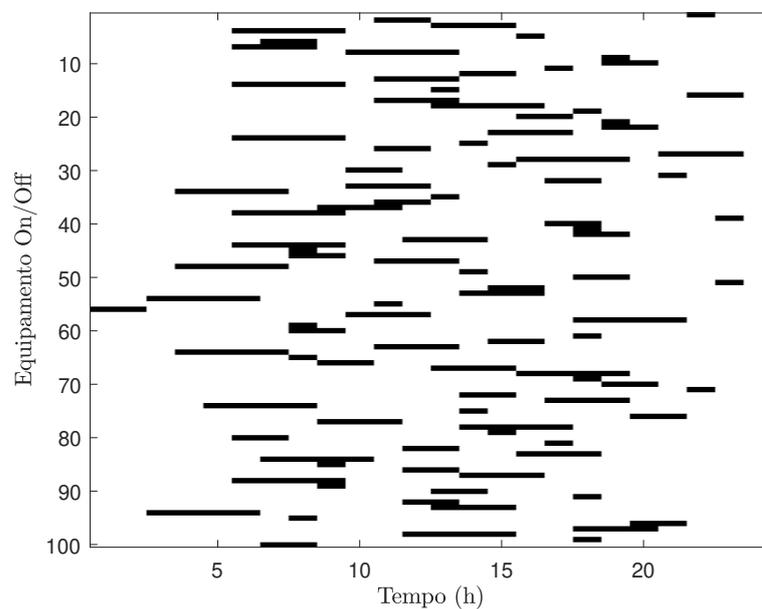
Fonte: Elaborada pelo autor

Figura B.15 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR).
Cenário com 100 cargas aplicando EPSO



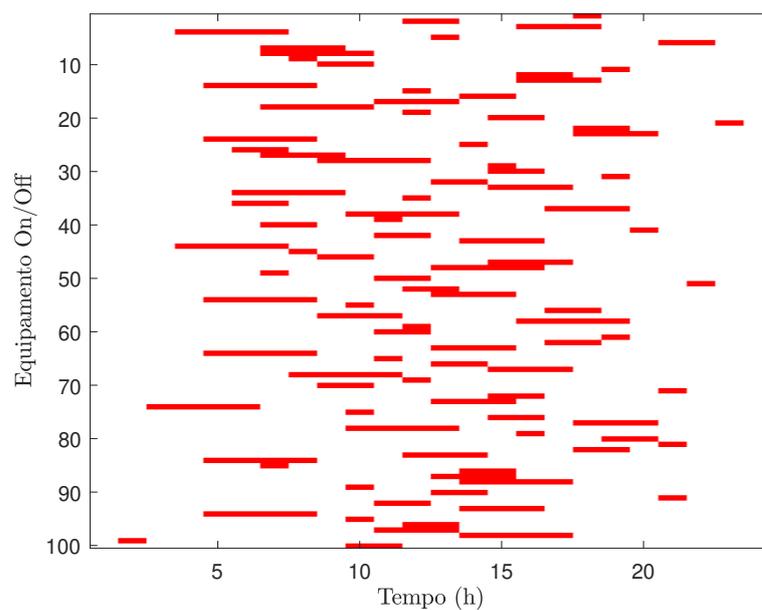
Fonte: Elaborada pelo autor

Figura B.16 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 100 cargas aplicando o método deslocamentos aleatórios com solução única no estilo *Greedy Search*



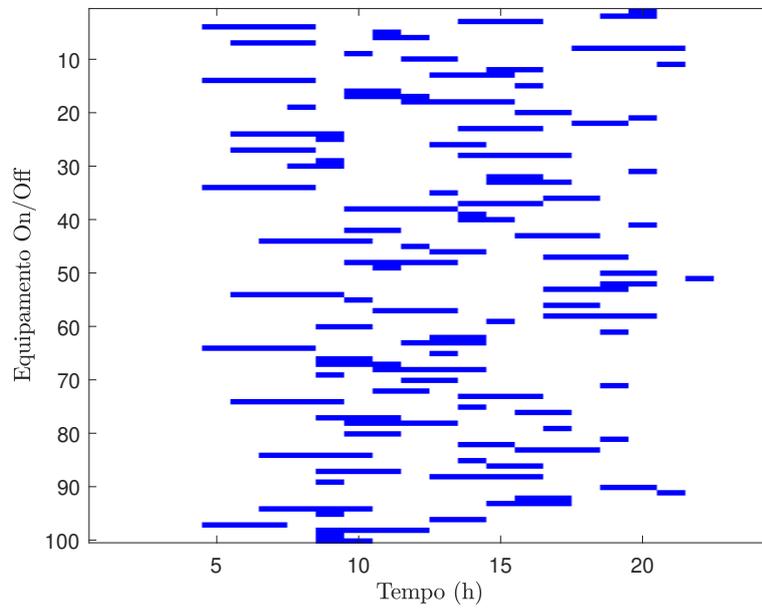
Fonte: Elaborada pelo autor

Figura B.17 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 100 cargas aplicando PSO



Fonte: Elaborada pelo autor

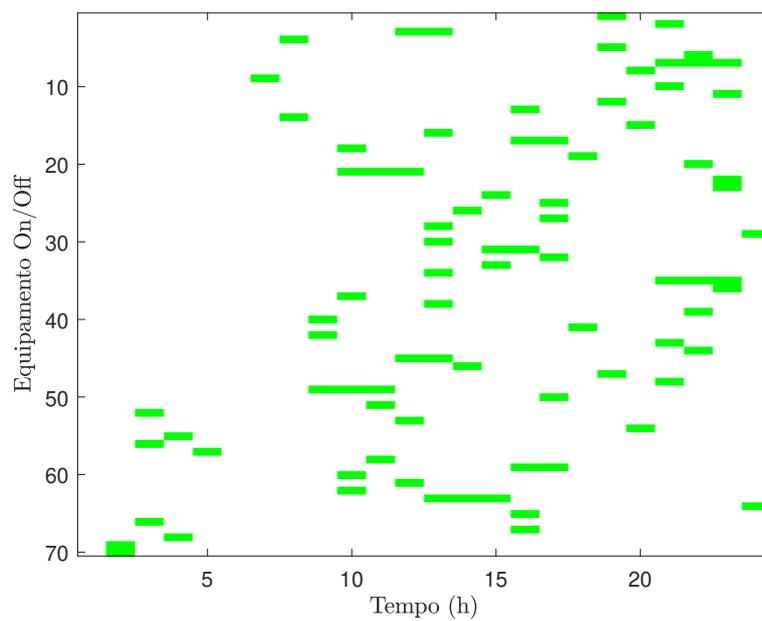
Figura B.18 – Instante de agendamento de cargas para o ponto de Pareto. Cenário com 100 cargas aplicando EPSO



Fonte: Elaborada pelo autor

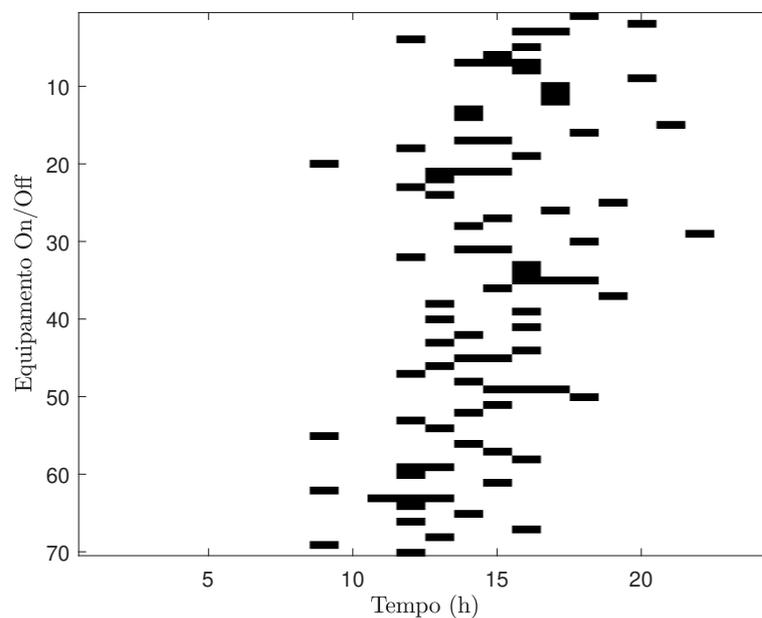
B.2 – ESTUDO DE CASO

Figura B.19 – Situação das cargas sem agendamento



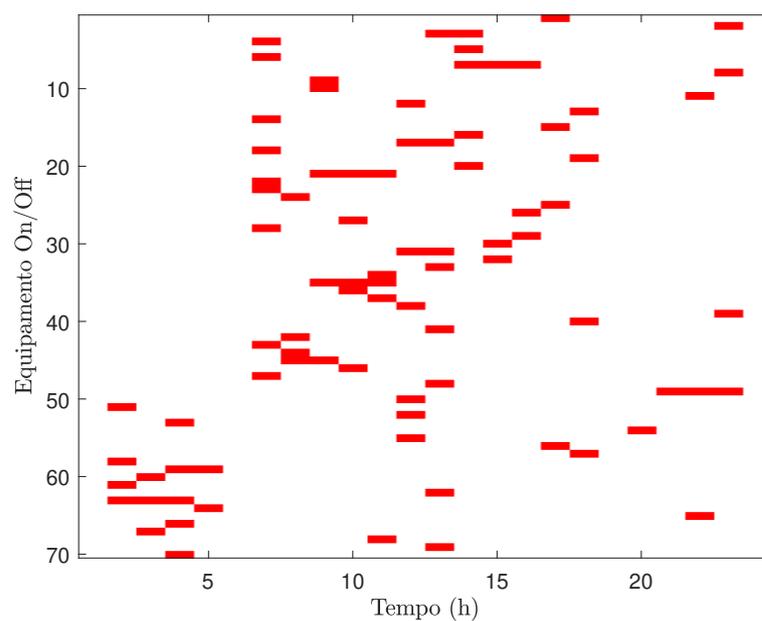
Fonte: Elaborada pelo autor

Figura B.20 – Instante de agendamento de cargas para $z = 1$ (Somente métrica custo) para curva de carga real. Cenário com 70 cargas aplicando E PSO.



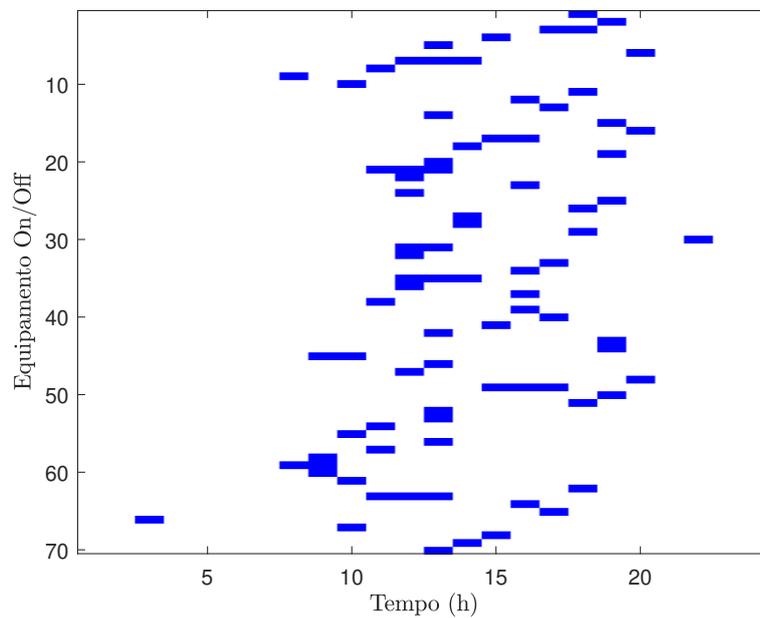
Fonte: Elaborada pelo autor

Figura B.21 – Instante de agendamento de cargas para $z = 0$ (Somente métrica PAPR) para curva de carga real. Cenário com 70 cargas aplicando E PSO.



Fonte: Elaborada pelo autor

Figura B.22 – Instante de agendamento de cargas para o ponto de Pareto para curva de carga real. Cenário com 70 cargas aplicando EPSO.



Fonte: Elaborada pelo autor