



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA ELÉTRICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**  
**MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA**

**ALYSSON DE LIMA PONCIANO**

**GERENCIAMENTO DE ENERGIA RESIDENCIAL: OTIMIZAÇÃO MULTIOBJETIVO  
COM MERCADO DE DUPLA CONTRATAÇÃO E RECURSOS DISTRIBUÍDOS**

**FORTALEZA**

**2025**

ALYSSON DE LIMA PONCIANO

GERENCIAMENTO DE ENERGIA RESIDENCIAL: OTIMIZAÇÃO MULTIOBJETIVO  
COM MERCADO DE DUPLA CONTRATAÇÃO E RECURSOS DISTRIBUÍDOS

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Engenharia Elétrica - Sistemas de Energia

Orientador: Prof. Dr. Giovanni Cordeiro Barroso

Coorientador: Prof. Dr. Lucas Silveira Melo

FORTALEZA

2025

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

---

P854g Ponciano, Alysson de Lima.  
Gerenciamento de energia residencial : otimização multiobjetivo com mercado de dupla contratação e recursos distribuídos / Alysson de Lima Ponciano. – 2025.  
85 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2025.

Orientação: Prof. Dr. Giovanni Cordeiro Barroso.

Coorientação: Prof. Dr. Lucas Silveira Melo.

1. Sistema de gerenciamento de energia. 2. Resposta da demanda. 3. Conforto. 4. Otimização. 5. Redes inteligentes. I. Título.

CDD 621.3

---

ALYSSON DE LIMA PONCIANO

GERENCIAMENTO DE ENERGIA RESIDENCIAL: OTIMIZAÇÃO MULTIOBJETIVO  
COM MERCADO DE DUPLA CONTRATAÇÃO E RECURSOS DISTRIBUÍDOS

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Engenharia Elétrica - Sistemas de Energia

Aprovada em:

BANCA EXAMINADORA

---

Prof. Dr. Giovanni Cordeiro Barroso (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Lucas Silveira Melo (Coorientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Raimundo Furtado Sampaio  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Jonatha Rodrigues da Costa  
Instituto Federal de Educação, Ciência e Tecnologia  
do Ceará (IFCE)

## **AGRADECIMENTOS**

Primeiramente a Deus por todo amor e provisão durante toda a minha vida, em que sem Ele nada eu posso e com Ele tudo eu posso. Que a honra e a glória de toda a minha vida seja dedicada a Deus.

A minha família que ofereceu todo o suporte nessa jornada, sem eles a trajetória seria muito mais difícil.

A minha namorada que com muito amor, palavras de incentivo e oração transformou o significado do mestrado para a construção de um futuro melhor para nós.

Aos meus professores orientadores Giovanni Barroso e Lucas Melo que forneceram as suas experiência em gestão para guiar o andamento da minha carreira acadêmica e tiveram apoio fundamental na construção deste trabalho. Saudações ao professor Raimundo Furtado e Daniel Jaguaribe por terem me incentivado a participar do programa de pós-graduação.

A todos os meus amigos e professores, em especial os do Grupo de Redes Elétricas Inteligentes, que colaboraram na caminhada do mestrado com conhecimento, companheirismo e momentos de confraternização.

"Ame o Senhor, o seu Deus, de todo o seu coração, de toda a sua alma e de todas as suas forças. Que todas estas palavras que hoje lhe ordeno estejam em seu coração."

(Dt 6:5-6)

## RESUMO

A transição energética tem contribuído para descentralização da geração de energia, promovendo a expansão da geração distribuída (GD) renovável instaladas próxima aos consumidores e contribuindo para a descarbonização do planeta. A expansão das GDs proporciona benefícios, no entanto sua característica intermitente e variável causa vários impactos. Para mitigar estes problemas tornou-se crescente o desenvolvimento e uso de sistemas inteligentes para gerenciamento de energia residencial baseados nos conceitos de Redes Elétricas Inteligentes. Nesse contexto, este trabalho tem como objetivo apresentar uma metodologia para desenvolvimento e implementação de um sistema de gerenciamento residencial multiobjetivo integrado a um ambiente de comercialização com dupla contratação de energia por meio de uma tarifação *day-ahead pricing* pelo mercado spot e fixa pelo mercado bilateral, Recursos Energéticos Distribuídos (DERs) e cenários estocásticos. A formulação matemática para o método de otimização Programação Linear Inteira Mista foi desenvolvida na linguagem *Python* com o solucionador CPLEX. Diferentes conjuntos de cargas e restrições são analisados para avaliar a performance do sistema proposto com relação ao tempo de simulação, influência na rede elétrica, operação do sistema de armazenamento, demanda energética negociada nos mercados bilateral e *spot*, demanda total e custo de operação diário. Para avaliação do sistema proposto, 40 simulações diferentes foram realizadas com 8 conjuntos de cargas e 5 conjuntos de regras. As regras adotadas abrangem: tempo de funcionamento, janela de tempo de operação, interruptibilidade, minimização do custo e desconforto. Os resultados obtidos mostram que os cenários que possuem menos restrições há um menor impacto financeiro, porém geram efeito rebote por criar um pico de demanda em um horário de baixa tarifação do mercado. A partir dos resultados obtidos, concluí-se também que ao acrescentar regras, aumenta o tempo de simulação e o custo financeiro, devido a menor liberdade de operação das cargas. Por fim, uma análise financeira mostra redução de custos entre 35% e 77% se optar por cenários com menos restrições comparado com apenas a minimização do conforto na função objetivo.

**Palavras-chave:** sistema de gerenciamento de energia; resposta da demanda; conforto; otimização; redes inteligentes.

## ABSTRACT

The energy transition has contributed to the decentralization of power generation, promoting the expansion of renewable distributed generation (DG) installed close to consumers and contributing to the decarbonization of the planet. The expansion of DGs offers benefits, but their intermittent and variable nature causes several impacts. To mitigate these problems, the development and use of intelligent residential energy management systems based on the concept of Smart Grids has become increasingly popular. In this context, this work aims to present a methodology for developing and implementing a multi-objective residential management system integrated into a commercialization environment with dual energy contracting through day-ahead pricing in the spot market and fixed pricing in the bilateral market, Distributed Energy Resources (DERs), and stochastic scenarios. The mathematical formulation for the Mixed Integer Linear Programming optimization method was developed in Python with the CPLEX solver. Different sets of loads and constraints are analyzed to evaluate the performance of the proposed system regarding simulation time, influence on the power grid, storage system operation, energy demand negotiated in the bilateral and spot markets, total demand, and daily operating cost. To evaluate the proposed system, 40 different simulations were performed with eight sets of loads and five sets of rules. The rules adopted cover operating time, operating window, interruptibility, cost minimization and discomfort. The results show that scenarios with fewer restrictions have a smaller financial impact, but generate a rebound effect by creating a peak in demand during a period of low market pricing. Based on the results, it can also be concluded that adding rules increases simulation time and financial costs due to less freedom in load operation. Finally, a financial analysis shows cost reductions of between 35% and 77% if scenarios with fewer restrictions are chosen compared to simply minimizing comfort in the objective function.

**Keywords:** energy management system; demand response; comfort; optimization; smart grids.

## LISTA DE FIGURAS

Figura 1 – Curvas básicas . . . . .	17
Figura 2 – Fases adotadas da Revisão Sistemática . . . . .	24
Figura 3 – Artigos remanescentes por fases . . . . .	25
Figura 4 – Trabalhos selecionados por data de publicação . . . . .	26
Figura 5 – Etapas dos estágios de contratação de energia . . . . .	35
Figura 6 – Combinação, soma e redução de cenários . . . . .	36
Figura 7 – Diferença positiva e negativa . . . . .	43
Figura 8 – Parâmetros de entrada e saída do CPLEX . . . . .	53
Figura 9 – Gráfico de calor com correlação . . . . .	54
Figura 10 – Preços tarifários do mercado <i>spot</i> e bilateral . . . . .	55
Figura 11 – Demanda Total para diferentes cargas e regras . . . . .	61
Figura 12 – Horários das 8 cargas ligadas para o conjunto de regra 1 . . . . .	62
Figura 13 – Horários das 8 cargas ligadas para o conjunto de regra 2 . . . . .	62
Figura 14 – Horários das 8 cargas ligadas para o conjunto de regra 3 . . . . .	63
Figura 15 – Horários das 8 cargas ligadas para o conjunto de regra 4 . . . . .	63
Figura 16 – Horários das 8 cargas ligadas para o conjunto de regra 5 . . . . .	64
Figura 17 – Potência <i>spot</i> comercializada . . . . .	65
Figura 18 – Potência bilateral comercializada . . . . .	66
Figura 19 – SOC da bateria . . . . .	67
Figura 20 – Custo acumulado ao longo do dia . . . . .	68
Figura 21 – Arquivos com extensão “.py” utilizados no Python . . . . .	85

## LISTA DE TABELAS

Tabela 1 – Formação dos termos para string de busca . . . . .	23
Tabela 2 – String genérica . . . . .	24
Tabela 3 – Pontuação do Score . . . . .	26
Tabela 4 – Comparativo dos trabalhos com a otimização MILP . . . . .	31
Tabela 5 – Definições das cargas . . . . .	38
Tabela 6 – Conjunto de cargas . . . . .	39
Tabela 7 – Nomenclatura para conjunto de regras e cargas . . . . .	51
Tabela 8 – Parâmetros da RD na rede elétrica . . . . .	56
Tabela 9 – Custo acumulado entre os conjuntos de cargas e regras . . . . .	59
Tabela 10 – Diferença percentual entre conjuntos de cargas e regras . . . . .	60
Tabela 11 – String do Web of Science . . . . .	82
Tabela 12 – String do Scopus . . . . .	82
Tabela 13 – String do Engineering Village . . . . .	82
Tabela 14 – String do IEEE Xplore . . . . .	82
Tabela 15 – Artigos selecionados para a fase 3 . . . . .	83
Tabela 16 – Bibliotecas e versões instaladas no ambiente . . . . .	84

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>12</b>
<b>1.1</b>	<b>Objetivos</b>	<b>14</b>
<i>1.1.1</i>	<i>Objetivo Principal</i>	<i>14</i>
<i>1.1.2</i>	<i>Objetivos Específicos</i>	<i>15</i>
<b>1.2</b>	<b>Descrição da Metodologia</b>	<b>15</b>
<b>1.3</b>	<b>Contribuições</b>	<b>15</b>
<i>1.3.1</i>	<i>Contribuições científicas</i>	<i>15</i>
<i>1.3.2</i>	<i>Artigos publicados</i>	<i>16</i>
<i>1.3.3</i>	<i>Código utilizado</i>	<i>16</i>
<b>1.4</b>	<b>Estrutura da Dissertação</b>	<b>16</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>17</b>
<b>2.1</b>	<b>Gerenciamento pelo Lado da Demanda</b>	<b>17</b>
<b>2.2</b>	<b>Resposta da Demanda</b>	<b>18</b>
<b>2.3</b>	<b>Estrutura de mercado</b>	<b>20</b>
<i>2.3.1</i>	<i>Mercado Bilateral</i>	<i>20</i>
<i>2.3.2</i>	<i>Mercado spot</i>	<i>20</i>
<i>2.3.3</i>	<i>Sintetização</i>	<i>21</i>
<b>3</b>	<b>REVISÃO SISTEMÁTICA</b>	<b>22</b>
<b>3.1</b>	<b>Método da Revisão Sistemática</b>	<b>22</b>
<i>3.1.1</i>	<i>Objetivo</i>	<i>22</i>
<i>3.1.2</i>	<i>Protocolo</i>	<i>22</i>
<i>3.1.2.1</i>	<i>Questões de pesquisa</i>	<i>22</i>
<i>3.1.2.2</i>	<i>Estratégias de busca</i>	<i>23</i>
<i>3.1.2.3</i>	<i>String de busca e palavras-chave</i>	<i>23</i>
<i>3.1.2.4</i>	<i>Crítérios de Seleção</i>	<i>24</i>
<i>3.1.3</i>	<i>Publicação dos resultados</i>	<i>26</i>
<i>3.1.4</i>	<i>Síntese</i>	<i>32</i>
<b>4</b>	<b>METODOLOGIA</b>	<b>33</b>
<b>4.1</b>	<b>Etapas para desenvolvimento</b>	<b>33</b>
<b>4.2</b>	<b>Estruturação</b>	<b>33</b>

4.2.1	<i>Dados de entrada</i>	34
4.2.2	<i>Estrutura de mercado</i>	34
4.3	<b>Formulação matemática</b>	36
4.3.1	<i>Parâmetros</i>	36
4.3.2	<i>Variáveis</i>	40
4.3.3	<i>Expressões</i>	43
4.3.4	<i>Função Objetivo</i>	44
4.3.5	<i>Restrições</i>	45
4.4	<b>Medidas de avaliação</b>	48
4.4.1	<i>Desempenho da rede</i>	48
4.4.2	<i>Simulação</i>	49
4.5	<b>Considerações</b>	50
5	<b>RESULTADOS</b>	51
5.1	<b>Tempo de Resposta</b>	52
5.2	<b>Desempenho da Resposta da Demanda</b>	54
6	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	69
6.1	<b>Trabalhos Futuros</b>	70
	<b>REFERÊNCIAS</b>	71
	<b>APÊNDICES</b>	82
	<b>APÊNDICE A</b> – <i>Strings utilizadas nas plataformas de busca</i>	82
	<b>APÊNDICE B</b> – <i>Artigos selecionados pela fase 3 da revisão sistemática</i>	83
	<b>APÊNDICE C</b> – <i>Bibliotecas instaladas no ambiente do Python</i>	84
	<b>APÊNDICE D</b> – <i>Estruturação do código</i>	85

## 1 INTRODUÇÃO

Nessa era da ciência e tecnologia, a humanidade foi abençoada com muitas tecnologias. Estas tecnologias têm deixado a vida das pessoas mais cômoda. O domínio da tecnologia da eletricidade é um dos feitos mais importantes já realizados pelo ser humano (Saboor *et al.*, 2018).

Por conseguinte, seja pelo crescimento da população ou desenvolvimento da economia, o consumo de eletricidade vem crescendo a cada dia (Nie *et al.*, 2023; Mahmood *et al.*, 2023; Shewale *et al.*, 2024; Waseem *et al.*, 2021a).

Por meio disso, o aumento da demanda de eletricidade força o setor de geração de energia a acionar fontes poluentes e adicionar mais gases de efeito estufa (GEE) na atmosfera, que é a principal causa do aquecimento global (Zhou *et al.*, 2023; Bukhsh *et al.*, 2018). Uma das alternativas para suprir essa demanda é a adição de novas fontes de energia; porém, segundo Latif *et al.* (2018) e Sadiq *et al.* (2021), a instalação de novas unidades de geração convencionais necessita de grandes investimentos e espaços para construção, dependendo do tipo de fonte.

Enquanto isso, os sistemas de potência em partes do mundo encontram-se em níveis de operação próximos de sua capacidade máxima. (Nie *et al.*, 2023; Besheer *et al.*, 2018). O balanço entre a demanda e a geração é um requisito fundamental para uma operação estável do sistema de potência. Para isso, Imran *et al.* (2020) afirma que, para aumentar a geração por fontes com baixos índices de Gases de Efeito Estufa (GEE), os pesquisadores têm proposto métodos de geração de energia usando fontes renováveis de energia. Mas Liang *et al.* (2020) diz que a intermitência e a incerteza provenientes das fontes de energia renovável trazem desafios significativos. Hussain *et al.* (2023) complementa que as fontes renováveis devem ser integradas com os sistemas de armazenamento de energia.

Sendo assim, Imran *et al.* (2020) diz que para utilizar efetivamente essas fontes, é necessária uma transformação das atuais redes de potência para redes inteligentes, já que Shewale *et al.* (2024) diz que as redes tradicionais não conseguem atender tamanha demanda. Para Hussain *et al.* (2023) essa transição energética está em andamento para satisfazer às demandas crescentes de energia.

O conceito de redes inteligentes surge com a introdução da tecnologia da informação e comunicação (TIC) na infraestrutura tradicional da rede (Javaid *et al.*, 2017). Sua principal função é controlar a geração, transmissão e distribuição de energia através de técnicas modernas (Imran *et al.*, 2020). Os principais objetivos das redes inteligentes são os acréscimos de eficiência,

economia de custos, autocura (capacidade de se recuperar das falhas de forma automática), auto-otimização, condicionamento à redução de poluentes, controle, confiabilidade e segurança para o sistema (Saboor *et al.*, 2018; Nadeem *et al.*, 2018; Bukhsh *et al.*, 2018). As redes inteligentes possuem diferentes tipos de dispositivos, como medidores inteligentes, cargas inteligentes e os Recursos Energéticos Distribuídos (REDs) (Imran *et al.*, 2020).

De acordo com Joo and Choi (2017) dois fatores são preponderantes para a utilização do sistema de gerenciamento residencial visando a redução de custos e mantendo a eficiência dos seus eletrodomésticos. Esses fatores são: a expansão habitacional e a introdução de cargas inteligentes. Os sistemas de gerenciamento de energia residencial (SGER) podem resolver os problemas da natureza intermitente das fontes renováveis e são vitais para gerenciar de forma ótima todas as cargas de uma residência (Bhamidi; Sivasubramani, 2020b). A função do SGER é monitorar, regular e otimizar o fluxo e o uso de energia (Reghukumar *et al.*, 2018).

De acordo com Bukhsh *et al.* (2018) e Hafeez *et al.* (2020a), o SGER tem duas grandes aplicações que são chamadas de Gerenciamento pelo Lado da Demanda (GLD) e gerenciamento pelo lado da geração (GLG). No lado da geração, o GLG atua no gerenciamento dos recursos da geração e confiabilidade do sistema. No lado do consumidor, a otimização do GLD modifica a curva de carga para reduzir os custos. Dessa forma, em uma infraestrutura da rede inteligente, o GLD controla o perfil de consumo de eletricidade do usuário (Khalid; Javaid, 2018).

Segundo Alfaverh *et al.* (2019) e Zhang *et al.* (2020), o SGER é uma ferramenta essencial para casas inteligentes, residência com cargas inteligentes, que desejam uma resposta da demanda (RD) eficiente em uma rede inteligente, pois os SGERs oferecem uma oportunidade para os consumidores participarem dos programas da RD ao agendar a operação das suas cargas em resposta às mudanças de preços. Para Zhang *et al.* (2015a), um requisito-chave para cargas inteligentes, cargas passíveis a automação, dentro de um contexto de redes inteligentes é a resposta da demanda. Huang *et al.* (2020) corrobora a informação ao dizer que os programas de resposta da demanda são vitais para as redes inteligentes, já que eles podem reduzir picos de cargas, consumo de energia e emissões de carbono.

Imran *et al.* (2020) sintetiza as informações ao dizer que as redes inteligentes permitem a integração da geração distribuída e das fontes renováveis de energia, além de envolver os usuários residenciais em programas de resposta da demanda e atividades do gerenciamento pelo lado da demanda.

Para Iqbal *et al.* (2020) os programas de RD ajudam os usuários a deslocar, controlar e interromper cargas residenciais por benefícios econômicos, estabilidade da rede e confiabilidade do sistema elétrico de potência. Dessa forma, um SGER com um programa de RD tenta identificar um agendamento das cargas ótimo que satisfaça as regras impostas da otimização e contemple os objetivos múltiplos.

Para determinar o agendamento é necessário desenvolver um algoritmo de otimização que contemple todas as restrições e objetivos do sistema e o SGER se torna responsável por ativar e desativar as cargas nos momentos ótimos, por exemplo: desligar em um momento de pico de consumo e ligar em um momento de baixo consumo. Devido ao agendamento do SGER, as cargas são movidas dos momentos de alta para baixa demanda e contribuem para o corte de pico na demanda e preenchimento de vales.

Logo, há necessidade de expandir os estudos no campo de algoritmos de otimização para implementação nos SGERs que atendam aos requisitos do consumidor e tragam benefícios para a rede elétrica.

Por fim, este trabalho visa a modelagem de um SGER para um modelo de resposta da demanda aplicado a residências com REDs utilizando cenários estocásticos. O modelo tarifário adotado é composto por duas tarifas, uma é chamada de *day-ahead pricing* (DAP), aqui denominado de mercado *spot* e a outra é um mercado de tarifa fixa, aqui denominado de mercado bilateral. Para a otimização do SGER é utilizada a Programação Linear Inteira Mista em linguagem *Python* com o solucionador *CPLEX*. Este trabalho representa uma evolução do estudo realizado por Melo (2022), utilizando-o como base e ampliando-o com a implementação da resposta à demanda.

## **1.1 Objetivos**

### ***1.1.1 Objetivo Principal***

O objetivo principal deste trabalho é apresentar a metodologia e implementação de um sistema de gerenciamento de energia residencial (SGER) multiobjetivo integrado a um ambiente de comercialização com dupla contratação de energia, REDs e cenários estocásticos.

### **1.1.2 *Objetivos Específicos***

No desenvolvimento deste trabalho foram definidos os seguintes objetivos específicos:

- Conceber, modelar e implementar um SGER para resposta da demanda para um cenário residencial;
- Integrar o modelo de mercado de dupla contratação;
- Integrar o modelo de cenários estocásticos e Recursos Energéticos Distribuídos;
- Integrar os conjuntos de regras e cargas para avaliar a dinâmica da resposta da demanda em diferentes ocasiões;
- Modelar e implementar o conforto, bem como avaliar seu impacto na residência e no sistema elétrico.

## **1.2 Descrição da Metodologia**

A metodologia para desenvolvimento deste trabalho compreende as seguintes etapas:

- Apresentar uma revisão sobre GLD, RD e os mercado de energia;
- Apresentar uma revisão sistemática do tema: Resposta da demanda em cenários residenciais;
- Direcionar a revisão sistemática para otimização MILP;
- Definir os modelos tarifários, recursos energéticos distribuídos, dados de geração e consumo, plataforma de otimização e solução utilizados na modelagem;
- Definir a formulação matemática da resposta da demanda e implementá-la em *Python*;
- Definir os cenários de avaliação;
- Validar e comparar os resultados obtidos dos cenários de avaliação por meio de indicadores diversos.

## **1.3 Contribuições**

### **1.3.1 *Contribuições científicas***

Este trabalho apresenta contribuições que distinguem de trabalhos já publicados. A utilização de um mercado de dupla contratação por meio de um mercado spot (*day-ahead pricing*) e mercado bilateral, com a utilização de cenários estocásticos para consumo fixo, geração e preço

*spot* e avaliação dos impactos causados do modelo proposto por meio de diferentes cenários de cargas e regras já são considerados diferenciais. Ademais, há toda a estrutura com modelagem da otimização MILP em Python utilizando a biblioteca Pyomo e o *solver* CPLEX, recursos energéticos distribuídos com fonte solar fotovoltaica e sistema de armazenamento em bateria e função multi-objetivo considerando a minimização do custo operacional diário e o desconforto marcado entre a diferença do tempo desejado e o tempo real de funcionamento da carga.

### **1.3.2 Artigos publicados**

Artigo com o título “Uma introdução à revisão sistemática da resposta da demanda do setor residencial” foi publicado na Revista Brasileira de Energia.

### **1.3.3 Código utilizado**

O código utilizado está disponível no GitHub por meio do link: <https://github.com/greiu-fc/smart-emanager>

## **1.4 Estrutura da Dissertação**

Esta dissertação está estruturada de acordo com os seguintes capítulos:

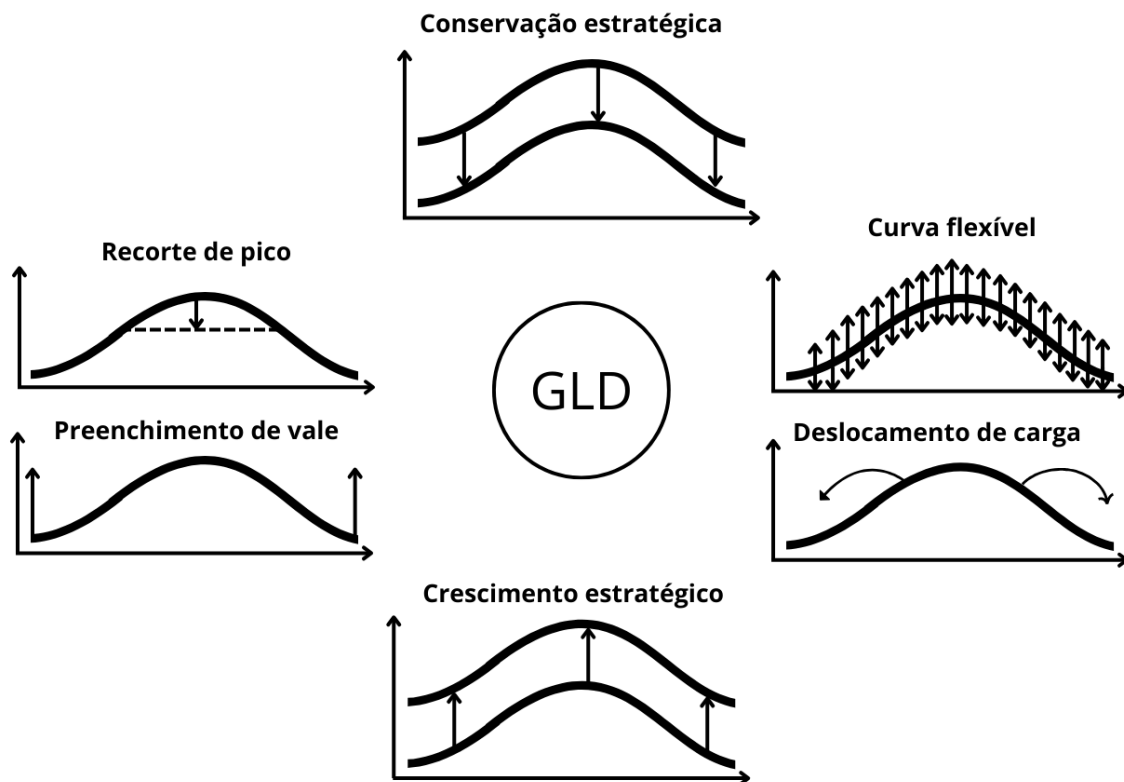
- no Capítulo 2 é apresentado o referencial teórico da resposta da demanda e sua estruturação;
- no Capítulo 3 é apresentada uma revisão sistemática sobre o tema da resposta da demanda aplicada em cenários residenciais e o destaque deste trabalho comparado à literatura existente;
- no Capítulo 4 está descrita a metodologia adotada nesse trabalho com informações sobre as bases de dados utilizadas, a formulação matemática e os parâmetros de avaliação;
- no Capítulo 5 são apresentados os resultados e as discussões acerca da metodologia;
- no Capítulo 6 é apresentada a conclusão com adição de trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Gerenciamento pelo Lado da Demanda

De acordo com Gellings (1985), o gerenciamento pelo lado da demanda (GLD) é o planejamento e a implementação das atividades pela distribuidora de energia que visam influenciar a mudança no formato da curva de consumo. Na Figura 1 são apresentados os 6 formatos de curvas básicas que podem ser atendidas por meio do GLD.

Figura 1 – Curvas básicas



Fonte: Adaptado de Gellings (1985)

Cada curva tem sua determinada funcionalidade e também explicação, logo a definição de cada uma segundo Gellings (1985) está descrito a seguir:

- Recorte de pico: é geralmente considerado como a redução de carga de pico por meio do controle de carga direto (*direct load control* - DLC);
- Preenchimento de vale: é associada com a adição de cargas em momentos de fora de pico;
- Deslocamento de carga: é o deslocamento das cargas de pico para momentos de fora de

pico;

- Conservação estratégica: é uma redução na curva de carga proveniente de programas para o usuário pelas distribuidoras, por exemplo, ações de eficiência energética;
- Crescimento estratégico: é um aumento na curva de carga, estimulada também pela distribuidora de energia;
- Curva flexível: conceitualmente ligado à confiabilidade, pois uma vez antecipada a curva de demanda do usuário, a concessionária de energia pode planejar a sua oferta.

De acordo com Gellings (2009), o gerenciamento de energia dinâmico é uma abordagem inovativa para gerenciar as cargas no lado da demanda. Sendo assim, o gerenciamento de energia dinâmico é composto por 4 componentes:

- Cargas inteligentes: cargas com conectividade e passíveis de controle para ativar e desativar;
- Recursos energéticos distribuídos: elementos como fontes solar fotovoltaica e eólica e sistemas de armazenamento de energia;
- Sistemas de controle avançado: sistema de gerenciamento de energia para controlar toda a infraestrutura da edificação.
- Arquitetura de comunicação integrada: a comunicação entre geração, armazenamento, cargas, redes e outros elementos deve ser integrado.

Segundo Jordehi (2020), o Sistema de Gerenciamento de Energia ajusta a operação liga-desliga das cargas de forma ótima. Além disso, o SGE pode usar uma interação bidirecional entre a rede elétrica e os usuários que permite a otimização da demanda de energia enquanto participa de programas da RD (Zhang *et al.*, 2020).

## 2.2 Resposta da Demanda

A resposta da demanda (RD) refere-se a mecanismos que gerenciam a demanda do consumidor em resposta às condições da geração, como reduzir o consumo de eletricidade em momentos de pico e em resposta ao preço do mercado (Gellings, 2009). Os programas de RD são baseados em dois grandes tipos: em preço e em incentivo.

De acordo com a BRASIL. Ministério de Minas e Energia. Empresa de Pesquisa Energética (2019), a RD baseada em preço refere-se à mudança na curva de carga do consumidor devido às flutuações de preço durante o dia. Sendo assim, o consumidor ou SGER realiza um deslocamento da carga para um momento em que a tarifa é mais baixa e, conseqüentemente,

uma menor utilização em momentos de tarifas mais altas.

Já a resposta da demanda baseada em incentivos oferece benefícios financeiros para os consumidores em troca da redução de carga por motivos de escassez ou confiabilidade na geração (BRASIL. Ministério de Minas e Energia. Empresa de Pesquisa Energética, 2019).

UNITED STATES. Department of Energy (2006) sintetiza os principais programas de resposta da demanda baseado em incentivos e em preços. Os baseados em preço são:

- Preço por tempo de uso (*Time-of-use* - TOU): tarifa composta por diferentes unidades de preço usando diferentes blocos de tempo. Por exemplo, no Brasil, tem-se a tarifa branca que é composta por 3 blocos de preços para os períodos de fora ponta, intermediário e ponta;
- Preço em tempo real (*Real-time pricing* - RTP): uma tarifa típica de variação horária ou em blocos de 15 minutos. As notificações dos preços podem ser relativas ao dia seguinte (*day-ahead*) ou na hora seguinte (*hour-ahead*);
- Preço de pico crítico (*Critical Peak Pricing* - CPP): a tarifação é uma hibridização entre TOU e RTP. Porém, a estrutura é similar a TOU, mas com preços de pico mais acentuados devido um evento que sobrecarregue a rede.

Quanto aos programas baseados em incentivos, o UNITED STATES. Department of Energy (2006) descreve-os como:

- Controle direto da carga (*Direct load control* - DLC): programa que o operador desliga remotamente uma carga do usuário e geralmente é aplicado aos consumidores residenciais e comerciais pequenos;
- Serviço interrompível/reduzível (*Interruptible/curtailable (I/C) service*): opções de corte que promovem descontos ou créditos de energia para redução de energia durante contingências e geralmente aplicados a grandes consumidores de energia elétrica;
- Programas de oferta de demanda/recompra (*Demand Bidding/Buyback Programs*): os consumidores ofertam reduções de energia com base nos preços de mercado. Geralmente aplicados a grande consumidores;
- Programas de resposta da demanda de emergência (*Emergency Demand Response Programs*): programa que providencia incentivos para os usuários minimizarem o uso de energia em períodos que a reserva de energia está prejudicada;
- Programas de mercado de capacidade (*Capacity Market Programs*): os operadores do sistema cortam blocos de carga previamente acordados com os consumidores. Os usuários

recebem notificação de quando acontecerá o evento e sofrem punições ao não executar as reduções de carga;

- Programas de mercado de serviços ancilares (*Ancillary Services Market Programs*): os consumidores oferecem cortes de cargas nos mercados como operação de reserva. Se a negociação for aceita, receberão um bônus financeiro por ficar com a carga desligada e quando for necessário o corte, eles são pagos com o preço do mercado *spot*.

## 2.3 Estrutura de mercado

A estrutura de mercado é muito importante para a aplicação da resposta da demanda, pois ela irá definir o programa de RD utilizado. A seguir são apresentados os dois ambientes de contratação de energia que são utilizados neste trabalho.

### 2.3.1 Mercado Bilateral

Neste mercado é realizada uma contratação entre dois agentes distintos, tendo assim o nome de mercado bilateral, efetivadas através da assinatura de um contrato denominado *Power Purchase Agreement* (PPA). É um mercado em que negocia-se uma potência máxima e pode pagar tarifas variadas ao longo do dia ou apenas uma única tarifa. A duração deste contrato firmado pode durar dias, meses ou anos, portanto, o comprador pode requisitar energia até o máximo contratado sem haver custos adicionais (Tavares, 2019). Esta modalidade também pode ser chamada de mercado futuro e, devido à característica de se usar uma tarifa única neste trabalho, logo será chamada de tarifa fixa. A tarifação é semelhante ao sistema tarifário vigente para consumidores de classe B no Brasil, porém sem a estrutura de comercialização e limite de potência máxima pré-estabelecido.

Este mercado é recomendado para manter uma previsibilidade de custo com uma tarifação conhecida e normalmente com valores inferiores ao mercado *spot*.

### 2.3.2 Mercado spot

Este mercado tem tarifação variante a cada hora ou 15 minutos, ou seja, dentro dos programas de RD tem semelhança com o RTP. Porém, a liquidação, que é o momento em que há o fechamento das negociações, pode acontecer com a configuração de dia seguinte, *Day-ahead pricing* (DAP), ou hora seguinte, *Hour-ahead pricing*. De acordo com Tavares (2019), a flutuação

dos preços é coincidente com a relação entre a disponibilidade da geração e a necessidade do consumidor. Sendo assim, o usuário pode buscar tanto a compra quanto a venda de energia neste mercado, o que estimula a participação de geração distribuída nas residências.

### **2.3.3 Sintetização**

O GLD, a Resposta da Demanda e a Estruturação de Mercado foram apresentados neste capítulo. Para este trabalho, as curvas básicas do GLD são consequência do remanejamento das cargas por meio do otimizador presente no SGER. A residência participa do programa de resposta da demanda baseado no preço por meio dos mercados bilateral e *spot*.

## 3 REVISÃO SISTEMÁTICA

### 3.1 Método da Revisão Sistemática

Este capítulo aborda o desenvolvimento de uma Revisão Sistemática (RS) de RD. Esta RS tem como objetivo identificar, analisar e interpretar as evidências disponíveis relacionadas com um particular tópico de pesquisa ou fenômeno de interesse (Nakagawa *et al.*, 2017). A RS é um procedimento robusto, confiável e auditável, ou seja, com um alto grau de reprodutibilidade. Porém, é necessário que os passos sejam bem descritos e executados. O aplicativo StArt<sup>1</sup> foi utilizado para gerenciar a RS por ser gratuito e possuir as principais funcionalidades para concentrar a RS em uma única plataforma.

#### 3.1.1 Objetivo

O objetivo desta RS é a identificação, classificação e sumarização das propostas de Programas de Resposta da Demanda (PRDs) com aplicações em residências entre janeiro de 2014 e abril de 2024.

#### 3.1.2 Protocolo

O protocolo é um roteiro a ser seguido durante o planejamento da RS. O principal objetivo do protocolo é evitar os vieses que podem ocorrer durante a execução da RS (Nakagawa *et al.*, 2017). O protocolo é definido por:

- Definição das questões de pesquisa;
- Definição das estratégias de busca;
- Definição das fontes de pesquisa;
- Definição dos critérios de seleção (Inclusão e Exclusão);
- Definição dos critérios de qualidade (não aplicado neste trabalho).

##### 3.1.2.1 Questões de pesquisa

As questões de pesquisa são as perguntas basilares que devem ser respondidas através do processo de extração dos artigos selecionados. Para a RS em questão, foram adotadas as

---

<sup>1</sup> Aplicativo desenvolvido pelo Laboratório de Pesquisa em Engenharia de Software da Universidade Federal de São Carlos

seguintes perguntas:

- Quais os tipos de programas de RD aplicados à residência e quais suas características?
- Quais são as soluções de RD aplicadas e suas respectivas técnicas de otimização?
- Quantas residências participam dos PRDs?
- Quais são as fontes de geração e armazenamento de energia presentes em PRDs?

### 3.1.2.2 Estratégias de busca

Para facilitar a aquisição de informação em bases de artigo no ramo de engenharia em nível internacional, foram selecionados 4 buscadores internacionais para filtrar os artigos por meios das *string*. Os motores de busca escolhidos são:

- Web of Science (<https://apps.webofknowledge.com/>);
- Scopus (<https://www.scopus.com/>);
- Engineering Village (<https://www.engineeringvillage.com/>);
- IEEE Xplore (<https://ieeexplore.ieee.org/>).

### 3.1.2.3 String de busca e palavras-chave

As *strings* de cada buscador tiveram como base a Tabela 1, em que os termos na horizontal são unidos pelo operador booleano “OR” e na vertical os termos são unidos pelo operador “AND”.

Tabela 1 – Formação dos termos para string de busca

Termos de Busca	Sinônimos	Plural	Abreviação
Demand Response	-	-	DR
Home	Residential, Domestic	-	-
Energy Management	Energy Efficiency	-	-
Scheduling	Shift*, adjustment, optimization	-	-

Fonte: Próprio autor.

A *string* genérica utilizada nos buscadores está contida na Tabela 2 e as suas variações específicas para *Web of Science*, *Scopus*, *Engineering Village* e *IEEE Xplore* estão presentes no Apêndice A nas Tabela 11, Tabela 12, Tabela 13 e Tabela 14, respectivamente.

Tabela 2 – String genérica

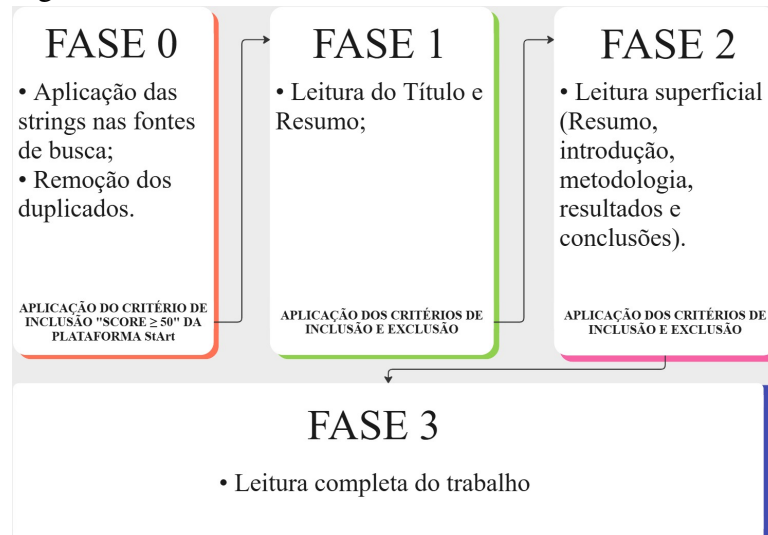
String
((Demand Response) OR DR) AND (home OR residential OR domestic) AND ((Energy Management) OR (Energy Efficiency)) AND (scheduling OR shift* OR adjustment OR optimization)

Fonte: Próprio autor.

### 3.1.2.4 Critérios de Seleção

Os critérios de seleção são responsáveis por definir quais artigos são aceitos e, conseqüentemente, passam para a próxima fase. Na Figura 2 são apresentadas as 4 fases adotadas para essa RS.

Figura 2 – Fases adotadas da Revisão Sistemática



Fonte: Próprio autor.

Os critérios que definem se um artigo passa para a fase seguinte ou não são estratificados em critérios de inclusão, em que todos devem ser aceitos, e critérios de exclusão, em que apenas um é suficiente para desclassificar o artigo para a etapa posterior. Os critérios de inclusão que foram selecionados:

- (I) Estudos publicados em português, inglês e espanhol;
- (I) Estudos com implementações de Resposta a Demanda e métodos de otimização em residências;
- (I) Estudos publicados entre 2014-2024.

Os seguintes critérios de exclusão foram adotados:

- (E) Estudos com implementações de resposta a demanda para indústrias;
- (E) Estudos não contemplados pelo critérios de inclusão;

- (E) Estudos com implementações de resposta a demanda para comércio;
- (E) Estudos em formato de resumo ou resumo estendido;
- (E) Estudos considerados *surveys* e *review*;
- (E) Repositório que não possui acesso pelo CAFE da Universidade Federal do Ceará ou está hospedado em um site com o idioma diferente de português, inglês ou espanhol;
- (E) Score do artigo na plataforma StArt inferior a 50;
- (E) Estudos que não abordam qual a proposta do programa de resposta da demanda.

Após seguir os passos expostos no fluxograma definido na Figura 2 e aplicar os critérios de seleção nas fases 1 e 2, o quantitativo de artigos resultantes de cada etapa está previsto na Figura 3.

Figura 3 – Artigos remanescentes por fases



Fonte: Próprio autor.

Na fase 0, 1.572 artigos foram considerados duplicados pelo software utilizado, em que a avaliação é feita através de uma comparação entre as informações bibliográficas extraídas dos artigos importados pelas extensões .bib e .ris. Outro critério utilizado na fase 0 para obter uma maior similaridade com o resultado desejado foi a utilização do *score* maior ou igual a 50. De tal forma que 3.545 artigos foram desclassificados por esse critério. O *score* do StArt é definido como o quantitativo de vezes que as palavras-chave e sinônimos aparecem no título, palavras-chave e resumo. Esse critério penaliza a escrita de forma que os termos solicitados aparecerão com uma frequência maior em artigos com *score* maior. Na Tabela 3 é mostrado o peso da ocorrência em cada um dos casos. Dessa forma, um artigo que possui 3 termos no título, 15 termos no resumo e 4 nas palavras-chave possui um *score* total de 68.

Tabela 3 – Pontuação do Score


Trecho	Pontuação por aparição
Título	5
Resumo	3
Palavras-chave	2

Fonte: Próprio autor.

### 3.1.3 Publicação dos resultados

A publicação dos resultados acontece após a consolidação da fase 3, em que os artigos resultantes responderão às questões de pesquisa. Como disposto na Figura 3, 113 artigos foram selecionados e chegaram à última fase. Na Figura 4 é mostrada a quantidade de artigos publicados por ano.

Figura 4 – Trabalhos selecionados por data de publicação



Fonte: Próprio autor.

No Apêndice B, na Tabela 15 são mostradas as referências dos artigos selecionados com base nos autores.

Dos 113 artigos publicados que foram resultados da RS proposta, apenas 20 utilizam o *Mixed-Integer Linear Programming* (MILP) como método de otimização da Resposta da Demanda residencial. Sendo esses os artigos do levantamento do estado da arte deste trabalho.

Yao *et al.* (2017) propõe um experimento com dois barramentos, no barramento DC é composta por placa solares e uma rede de alimentação AC com retificador, no barramento AC possui uma ligação com a barra DC por meio de um inversor e também é composta por cargas interruptíveis, não interruptíveis e variáveis e o sistema de gerenciamento residencial. Otimização MILP foi utilizada com o esquema de *day-ahead pricing* (DAP) na linguagem C++ utilizando o GNU Linear Programming KIT (GLPK) para minimizar o custo de energia e o

tempo de espera. Análises mostram que houve uma maior redução do custo de energia em tempos ensolarados, cujo valor foi de 39,11% devido à presença das placas solares, enquanto no tempo nublado houve uma redução de apenas 27,6%.

Zhang *et al.* (2015a) propõe um modelo de aquisição de dados de um simulador de energia eQuest integrado com o Matlab para avaliação da resposta da demanda de uma casa localizada em Springfield, Estados Unidos com a tarifa DAP. As cargas do sistema de Aquecimento, Ventilação e Ar-Condicionado (AVAC) são solucionadas através de técnicas lineares ou não-lineares, enquanto as cargas transferíveis utilizam programação inteira binária. O artigo conclui que a solução ótima para cargas fixas, reguláveis e transferíveis são iguais se as políticas forem agrupadas ou somando as políticas individuais. O custo diário de energia com a política de Resposta da Demanda foi de US\$2,94, em contrapartida com os US\$3,26 sem a política, que representa 9,81% de redução.

Panwar *et al.* (2017) propõe uma análise de benefícios para os consumidores, agregadores e distribuidoras de energia, respectivamente, *demand response provider* (DRP), *demand response provider agent* (DRPA) e *distribution system operator* (DSO). Dois níveis de otimização são utilizados, o primeiro visa à minimização do custo de energia do cliente com o MILP, enquanto o segundo visa à maximização dos lucros e do nivelamento de carga com *Mixed Integer Quadratic Programming* (MIQP). O esquema IEEE 34 barras foi simulado no Matlab com a tarifação Time of Use (TOU) em casos de agendamento de cargas para o dia seguinte e em tempo real para uma análise de cenários com resposta da demanda residencial estática e dinâmica, em que se difere na quantidade e instantaneidade de informações entre o DRP e DRPA.

Taik and Kiss (2021) propõe um sistema de dois estágios, sendo o primeiro otimizado por Mixed Integer Programming (MIP) que visa o agendamento das cargas, enquanto o segundo é otimizado por Model Predictive Control (MPC) que controla o conforto térmico. Utilizando a tarifa TOU em simulação no Matlab obteve sucesso em minimizar o custo de eletricidade e o desconforto térmico das cargas deslocáveis e não deslocáveis.

Tostado-Veliz *et al.* (2023) propõe uma abordagem de um programa de gerenciamento de energia de casa com 4 intervalos, divididos em problemas determinísticos, incertezas dos veículos elétricos, incertezas de parâmetros remanescentes e problemas de ajustes. A natureza do problema é MILP e foi simulada no Matlab para a inclusão de veículos elétricos com a tecnologia *vehicle-to-home* (V2H) e fonte solar fotovoltaica com o esquema de tarifa sendo *Real Time Pricing* (RTP). Cenários esperados, pessimistas e otimistas são analisados.

Rastegar *et al.* (2018) propõe um algoritmo de gerenciamento de energia residencial de duas camadas, em que a primeira visa a redução do custo de eletricidade e a segunda visa o achatamento da curva e reagendamento de cargas sem custos adicionais. As camadas são MILP e MIPQ, respectivamente, em que são solucionadas pela plataforma *General Algebraic Modeling System (GAMS)* com o *solver* CPLEX utilizando o esquema tarifário TOU para o alimentador teste de 34 nós do IEEE com cargas controláveis e não controláveis. Os experimentos mostraram que as duas camadas ajudam a evitar o efeito rebote de pico nos períodos de baixos valores tarifários, já que consideram benefícios para os consumidores e também para o operador do sistema.

Elkazaz *et al.* (2020) propõe um sistema hierárquico de duas camadas com cargas deslocáveis e tarifação TOU, em que a primeira é responsável por gerenciar o consumo de energia da residência e a segunda é responsável pelo sistema de armazenamento de energia na bateria visando a minimização da energia perdida resultante de incertezas de previsão e o tempo de amostragem. No Matlab, a otimização MILP foi utilizada para o MPC na primeira camada e um algoritmo baseado em regras para o *Real-Time Controller* da segunda camada. O trabalho mostra uma comparação entre o sistema hierárquico de duas camadas e de uma camada, em que o modelo de duas camadas supera 12,3% no autoconsumo de energia fotovoltaica e redução de 27,8% de custo anual de eletricidade.

Mahmoudi *et al.* (2020) propõe um modelo de operações ótimas de cargas para os próximos 5 minutos que consegue lidar bem com as incertezas do preço da energia. As cargas são categorizadas como interruptível e deslocável, não interruptível e deslocável e não interruptível e não deslocável. Baterias e fonte solar fotovoltaica foram utilizadas no modelo com o programa TOU e algoritmo MILP utilizado no Python.

Joo and Choi (2017) propõem um sistema de gerenciamento de dois níveis, o local é responsável pelo agendamento de cargas conforme o conforto de cada residência, enquanto o global é responsável pelo gerenciamento das baterias entre todas as residências, troca de energia entre os vizinhos e o cálculo do custo ótimo para todas as residências. No Matlab, a otimização MILP foi utilizada para minimizar o custo de energia e manter o conforto térmico. As casas possuem placas solares fotovoltaicas e baterias. Um esquema de preço TOU e diferentes esquemas de topologias foram testadas, sendo a topologia de malha melhor que radial e anel. Embora os custos da metodologia descentralizada proposta foram parecidos com uma centralizada, há benefícios no que tange o desempenho computacional, conforto e segurança cibernética.

Nan *et al.* (2018) propõe a simulação de uma comunidade com agregador para múltiplas residências de Suzhou, província de Jiangsu, China. No Matlab, MILP foi aplicado para 3 cenários distintos, TOU com *Interruptible load* (IL), *Critical Peak Pricing* (CPP) com IL e RTP com IL, todos com fontes de energia solar, rede de alimentação e armazenamento de baterias e geração solar fotovoltaica para minimização do custo de energia e conforto. Cargas interruptíveis, ajustáveis e deslocáveis foram consideradas. O cenário considerando TOU com IL obteve um melhor desempenho em comparação com os outros.

Yao *et al.* (2016) propõe um experimento utilizando geração solar fotovoltaica, baterias, rede de alimentação no barramento DC, um barramento AC com cargas e o sistema de gerenciamento residencial. Otimização MILP foi utilizada com o esquema de *day-ahead pricing* (DAP) na linguagem C++, utilizando o GNU Linear Programming KIT (GLPK). Análises mostram que houve uma maior redução do custo de energia em tempos ensolarados, cujo valor foi de 81,28% devido à presença das placas solares, enquanto durante o tempo nublado houve uma redução de apenas 23,78%.

Gazafroudi *et al.* (2019) propõe um sistema de gerenciamento de energia de dois estágios estocásticos, o primeiro é o estágio do dia seguinte, etapa em que são tratadas as incertezas do preço da eletricidade e da geração de energia fotovoltaica. As cargas são definidas como controláveis, deslocáveis e não controláveis e não deslocáveis. No estágio de tempo real, os cenários estocásticos são usados para considerar as incertezas que afetam o sistema. A natureza do problema é MILP e foi resolvida com o General Algebraic Modeling System (GAMS).

Nezhad *et al.* (2022) propõe um *Shrinking Horizon Model Predictive Controller* (SH-MPC) que visa o deslocamento de cargas e possui uma otimização em MILP para minimizar o custo de energia. Foram testados 3 cenários para RTP e TOU considerando ou não as baterias, placas solares fotovoltaicas e o SH-MPC. Conclui-se que o SH-MPC ajuda a mitigar os custos de eletricidade para ambos os casos, inclusive gerando lucros para o consumidor no caso do SH-MPC com bateria e fonte solar fotovoltaica.

Dinh *et al.* (2022) propõe um reconhecimento de padrões das cargas utilizando redes neurais profundas (DNN) para aproximar a otimização MILP usando aprendizagem supervisionada. O controle é feito nas baterias e nas fontes renováveis para obter a minimização do custo diário de energia e maximizar o conforto. Foi observado que, para os casos em que os usuários possuem um comportamento caótico (aleatório) nos usos da carga, o modelo proposto possui um menor rendimento.

Rajasekhar and Pindoriya (2015) propõem um sistema de gerenciamento de energia residencial de multiestágios contendo baterias, placas solares fotovoltaicas e agregador de energia, em que o primeiro estágio visa a minimização do custo de eletricidade e desconforto, o segundo estágio visa a minimização do custo de eletricidade, custo de utilização da bateria e razão pico-média e o terceiro estágio visa a modelagem das funções objetivos. A otimização foi resolvida por MILP-*Non-Dominated Sorting Genetic Algorithm 2* (NSGA II) e *Multi-Objective Genetic Algorithm* (MOGA) para o esquema tarifário DAP. Resultados mostram que a razão de pico-média reduziu em 7,28% e o custo diário de eletricidade reduziu em 11,26%

Tostado-Veliz *et al.* (2022) propõe 3 novas abordagens para tratar os problemas da resposta a demanda. Métricas como *Load Factor* (LF) e *Average Ramping indexed* (ARI) são utilizadas para validar as estratégias de recorte de pico e suavização da curva em casos de prosumidores. A metodologia utilizada consegue melhorar os índices propostos, reduzir a demanda de pico com um leve acréscimo da conta de energia. No Matlab, a função objetivo visa minimizar o custo de energia com parâmetros de penalização das estratégias dos programas de RD. São utilizadas 4 estratégias tarifárias: (1) Apenas TOU; (2) TOU com *inclining block rate* (IBR); (3) TOU com corte de pico; (4) TOU com IBR e corte de pico.

Ojand and Dagdougui (2022) propõem um sistema com agregador de energia gerenciando uma comunidade com baterias, uma fazenda de geração solar fotovoltaica e 60 residências com veículos elétricos e suas variedades de cargas. Utilizando uma otimização no Matlab de dois níveis com o MILP-MPC ajustando o dia seguinte, enquanto o *Q-learning* ajusta o tempo real ao lidar com as incertezas. A minimização visa reduzir a operação e o custo de degradação das baterias do carro e do sistema de armazenamento. Foi observado que, operando no modo de agregação de residências há melhores benefícios que residências sozinhas.

Bhamidi and Sivasubramani (2020b) propõem duas camadas de otimização no Matlab, em que a primeira é responsável por minimizar o custo presente mínimo/ciclo total de vida utilizando Particle Swarm Optimization (PSO) e a segunda é minimizar o custo de energia diário e o desconforto utilizando MILP. Nos cenários considerando bateria, geração solar fotovoltaica e turbinas eólicas com o programa TOU foi possível encontrar retornos satisfatórios em análises técnico-econômicas com *payback* de 4,1 anos.

Zamanloo *et al.* (2021) propõe uma otimização em dois níveis, em que no primeiro é feita uma minimização dos custos, enquanto no segundo nível é almejada a redução do fator de potência. Utilizando um algoritmo MILP com o solver CPLEX para o modelo contendo cargas

do tipo interruptíveis, não-interruptíveis e cargas termostaticamente controladas com geração solar fotovoltaica, turbinas eólicas, veículos elétricos e baterias é obtido sucesso na minimização dos custos e a maximização do fator de potência.

Bhamidi and Sivasubramani (2020a) propõem uma micro-grid residencial com baterias, geração solar fotovoltaica, turbinas eólicas, motor a diesel, microturbinas e residências. Cenários sem agendamento e com agendamento para 100, 500 e 1000 residências foram simulados. MILP com o SCIP *solver* foi utilizado para otimização da minimização do custo anual total e emissões anuais totais da microrrede. Resultados mostram que a participação de mais participantes na microrrede provoca uma redução dos custos e nas emissões totais.

O presente trabalho visa a aplicação de um sistema de gerenciamento de energia residencial estocástico utilizando Python com o *solver* CPLEX. Cargas deslocáveis e não deslocáveis em conjunto com sistema de baterias, fonte solar fotovoltaica e dois esquemas de contratação de energia pelo RTP e tarifa fixa estão presentes. As simulações para uma única residência visam a minimização do custo de energia e do desconforto definido como o tempo de espera do tempo desejado para o real. Na Tabela 4 é mostrada a comparação deste trabalho com os 20 artigos citados anteriormente, em que VE significa veículos elétricos, ESS significa sistema de armazenamento de baterias, PV significa fonte de geração solar, Eólica significa fonte de geração eólica, MD significa fonte de geração por motor a diesel. Para as descrições do programa, o DAP significa *Day-Ahead Pricing*, TOU significa *Time-of-Use*, CPP significa *Critical Peak Pricing*, IL significa *Interruptible load* e RTP significa *Real Time Pricing*.

Tabela 4 – Comparativo dos trabalhos com a otimização MILP

Ref.	Metodologia	VE	ESS	FV	Eólica	MD	Função objetivo	Residências	Descrição do Programa	Software
(Yao <i>et al.</i> , 2017)	Simulada	X	X	✓	X	X	Multi-Objetivo	Única	DAP	C++ (GLPK)
(Zhang <i>et al.</i> , 2015a)	Simulada	X	X	X	X	X	Mono-Objetivo	Única	DAP	Matlab
(Panwar <i>et al.</i> , 2017)	Simulada	X	X	X	X	X	Multi-Objetivo	Única	TOU	Matlab
(Taik; Kiss, 2021)	Simulada	X	X	X	X	X	Multi-Objetivo	Única	TOU	Matlab
(Tostado-Veliz <i>et al.</i> , 2023)	Simulada	✓	X	✓	X	X	Mono-Objetivo	Única	RTP	Matlab
(Rastegar <i>et al.</i> , 2018)	Simulada	X	X	X	X	X	Multi-Objetivo	Múltiplas	TOU	GAMS-CPLEX
(Elkazaz <i>et al.</i> , 2020)	Embarcada	X	✓	✓	X	X	Multi-Objetivo	Única	TOU	Matlab
(Mahmoudi <i>et al.</i> , 2020)	Simulada	X	✓	✓	X	X	Mono-Objetivo	Única	RTP	Python (3.6.2)
(Joo; Choi, 2017)	Simulada	X	✓	✓	X	X	Multi-Objetivo	Múltiplas	TOU	Matlab
(Nan <i>et al.</i> , 2018)	Simulada	X	✓	✓	X	X	Mono-Objetivo	Múltiplas	TOU, RTP, CPP e IL	CPLEX
(Yao <i>et al.</i> , 2016)	Simulada	X	✓	✓	X	X	Mono-Objetivo	Única	DAP	C++ (GLPK)
(Gazafroudi <i>et al.</i> , 2019)	Simulada	X	✓	✓	X	X	Multi-Objetivo	Única	RTP e DAP	Não informado
(Nezhad <i>et al.</i> , 2022)	Simulada	X	✓	✓	X	X	Mono-Objetivo	Única	TOU e RTP	Matlab
(Dinh <i>et al.</i> , 2022)	Simulada	X	✓	✓	X	X	Mono-Objetivo	Única	RTP	Não informado
(Rajasekhar; Pindoriya, 2015)	Simulada	X	✓	✓	X	X	Multi-Objetivo	Única	DAP	Matlab
(Tostado-Veliz <i>et al.</i> , 2022)	Simulada	✓	✓	✓	X	X	Mono-Objetivo	Única	TOU	Matlab
(Ojand; Dagdougui, 2022)	Simulada	✓	✓	✓	X	X	Multi-Objetivo	Múltiplas	RTP	Matlab
(Bhamidi; Sivasubramani, 2020b)	Simulada	X	✓	✓	✓	X	Multi-Objetivo	Única	TOU	Matlab
(Zamanloo <i>et al.</i> , 2021)	Simulada	✓	✓	✓	✓	X	Multi-Objetivo	Única	TOU e RTP	CPLEX
(Bhamidi; Sivasubramani, 2020a)	Simulada	X	✓	✓	✓	✓	Multi-Objetivo	Múltiplas	TOU	Matlab
Este trabalho	Simulada	X	✓	✓	X	X	Multi-Objetivo	Única	DAP + Tarifa fixa	Python (CPLEX)

Fonte: Próprio autor.

### 3.1.4 Síntese

Neste capítulo é introduzido o desenvolvimento de uma revisão sistemática sobre resposta da demanda com aplicações em cenários residenciais. Em seguida, para realizar uma comparação com este trabalho em termos de otimização MILP é realizada uma filtragem de 20 artigos dos 113 selecionados que são resultados do processo da revisão sistemática. Por fim, é apresentado um resumo de cada um dos 20 artigos selecionados e uma comparação é feita com as principais características desta natureza de artigo. Logo, este trabalho se distingue dos outros principalmente por meio da utilização de um mercado de contratação dupla e utilizando a linguagem Python com o *solver* CPLEX.

## 4 METODOLOGIA

Neste capítulo é apresentado o desenvolvimento do Sistema de Gerenciamento de Energia Residencial por meio da linguagem Python, em que são apresentadas as formulações matemáticas, as ferramentas, o método de otimização, a estruturação estocástica, os dados de entrada e as ferramentas de avaliação.

### 4.1 Etapas para desenvolvimento

O algoritmo de otimização Programação Inteira Linear Mista (Mixed-Integer Linear Programming - MILP) foi utilizado para resolver o problema multiobjetivo que envolve a minimização do custo e desconforto da RD. A sua natureza é um método exato, ou seja, de encontrar as respostas definitivas e não aproximadas. Para isso, é necessário expressar a formulação matemática da função objetivo, restrições, parâmetros e variáveis em algum software computacional.

### 4.2 Estruturação

O Sistema de Gerenciamento de Energia Residencial proposto utiliza a linguagem *Python* e seus componentes em versões específicas, para isso as bibliotecas foram instaladas em um ambiente diferente do ambiente nativo. As bibliotecas e as versões utilizadas neste trabalho encontram-se no Apêndice C. Nativamente, o *Python* não consegue interpretar a linguagem matemática para a otimização MILP. Sendo assim, foi utilizada a biblioteca *Pyomo* para redigir a formulação matemática no *Python*. Segundo Hart *et al.* (2011), o *Pyomo* é uma biblioteca de código aberto para modelagem e solução de programação matemática em *Python* e pode ser usado para definir problemas concretos e abstratos, criar instâncias de problemas e resolver essas instâncias com *solvers*. A licença acadêmica do *IBM ILOG CPLEX Optimization Studio 22.1.0* foi utilizado como solucionador do problema definido.

A estrutura de código utilizada para este trabalho tem como base 4 principais arquivos na extensão ".py". Esta descrição está contida no Apêndice D.

#### 4.2.1 *Dados de entrada*

Este trabalho é uma continuação dos trabalhos de Melo (2022) e Tavares (2019), logo as condições iniciais serão replicadas, como os dados de entrada, bibliotecas, linguagem e tratamento de estocasticidade. Os dados de geração e consumo foram retirados da biblioteca *SimBench* (Spalhoff *et al.*, 2019). Nesse caso, o consumo é o valor único de kW a cada 15 minutos da residência, ou seja, não subdivide em cargas, sendo assim, os dados de consumo são considerados como cargas não deslocáveis, não redutíveis e não controláveis e com 96 dados em um dia. Os dados do mercado de energia elétrica foram retirados do *Nord Pool Market* (Energinet, 2020). Como os dados coletados são horários, assim é necessário uma transformação para Espaços de Tempo de Operação (ETO) de 15 minutos, logo o vetor de 24 espaços de tempo em 1 hora foram transformados em 96 espaços de 15 minutos e as tarifas contidas dentro do intervalo de 1 hora foram repetidas para 4 ETO de 15 minutos.

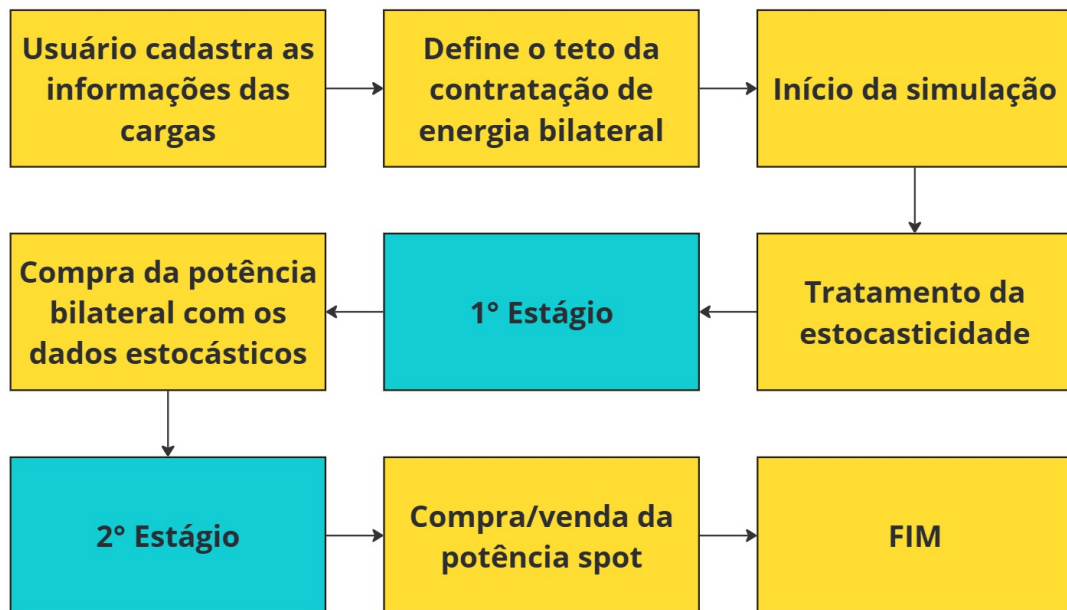
No desenvolvimento do trabalho adotou-se cenários estocásticos de geração de energia elétrica por painéis solares fotovoltaicos, consumo de energia elétrica residencial e valores tarifários de energia para lidar com as incertezas de compra de energia no mercado *spot*. O gerenciamento dos cenários da programação estocástica foi desenvolvida com o uso da biblioteca *PySP*. A biblioteca *Rapper* é utilizada para fazer uma interface entre a biblioteca *PySP* com o *Pyomo*.

#### 4.2.2 *Estrutura de mercado*

A estrutura de mercado adotada neste trabalho é semelhante ao executado em Tavares (2019) que foi baseada em Kok (2013) e Zinaman *et al.* (2015) e utilizada por Melo (2022) e Santos (2022). Ela é definida como um problema de dois estágios: no primeiro são determinados previamente o quantitativo de energia elétrica a ser comprado no mercado bilateral e no estado de carga da bateria; no segundo define-se a compra ou venda de energia no mercado *spot* após a consolidação do mercado bilateral. A natureza estocástica é caracterizada pela incerteza proveniente do mercado *spot*, pois a liquidação financeira do quanto será pago acontece em um momento posterior à compra da energia no mercado bilateral. Portanto, o Sistema de Gerenciamento de Energia compra energia elétrica inicialmente no mercado bilateral, utilizando os dados históricos de consumo, geração e preço do mercado *spot*. Após a consolidação da compra no mercado bilateral, é realizada a negociação no mercado *spot*. Na Figura 5 são

mostradas as etapas de funcionamento dos estágios de contratação de energia. O resultado final é o deslocamento das cargas visando otimizar a função multiobjetivo ponderando a compra de energia elétrica no mercado *spot* e bilateral.

Figura 5 – Etapas dos estágios de contratação de energia



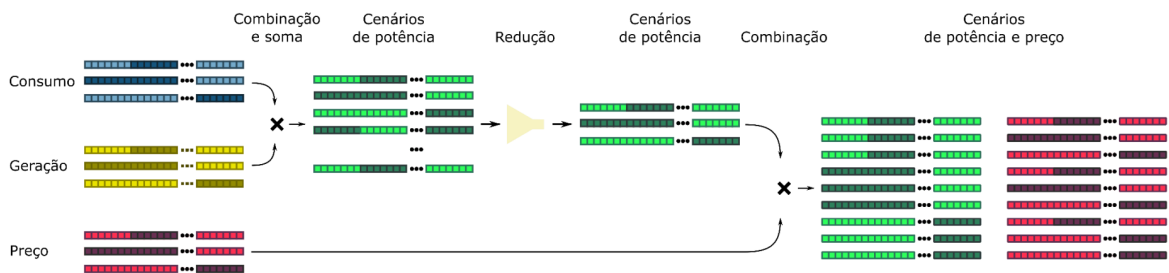
Fonte: Próprio autor.

Como prática padrão para obter cenários estocásticos realistas em problemas de otimização sob incerteza é necessário selecionar métodos para obter os dados de entrada, nesse caso adotou-se o Método de Monte Carlo (MCC) para adequação dos dados históricos em cenários de probabilidades. As datas mensais utilizadas para consumo e geração são do período de 15/02/2016 a 16/03/2016 e 19/09/2019 a 19/10/2019 para os preços. Devido a quantidade de cenários provenientes das datas selecionadas, a multiplicação dos cenários semanais de consumo, geração e preço torna a solução computacionalmente exaustiva; para isso, adotou-se a distância de Kantorovich com o intuito de reduzir a quantidade de cenários e, conseqüentemente, o esforço computacional.

Na Figura 6 são apresentadas as etapas de combinação, soma e redução de cenários utilizadas. Esse procedimento é necessário para reduzir o esforço computacional gerado pela quantidade excessiva de cenários obtidos durante as etapas. Considerando hipoteticamente 9 cenários de geração, consumo e preço, gerariam 729 cenários para análise. A metodologia

adotada considera inicialmente 3 cenários para geração, consumo e preço coletados dentro do espaço temporal definido anteriormente; em seguida, são combinados 3 cenários de geração com os 3 de consumo, o que resulta em 9 cenários de potência líquida. Estes são reduzidos para 3 e combinados com os cenários de preço, finalizando com 9 cenários totais. Por fim, esses cenários são utilizados para aplicação da RD. Para as medidas de avaliação em diversas situações, foi selecionado um único cenário, embora tenham sido processados outros cenários, pois necessita-se de dados de entrada iguais para avaliar os impactos causados pela implementação da RD.

Figura 6 – Combinação, soma e redução de cenários



Fonte: (Tavares, 2019)

## 4.3 Formulação matemática

### 4.3.1 Parâmetros

Os parâmetros são os dados de entrada do problema como tempos, cargas, potência, preço, bateria e resposta da demanda estão contempladas na formulação.

A unidade de tempo  $t$  utilizada é Espaço de Tempo de Operação (ETO) de 15 minutos, de forma que em um dia há 96 ETOs. Logo, o parâmetro de tempo está definido conforme a Equação 4.1.

$$T = \{t \in \mathbb{Z} \mid 0 \leq t \leq 95\} \quad (4.1)$$

O conceito de cargas deslocáveis utilizado é representado por um conjunto de equipamentos eletro eletrônicos com tempo de operação diário. Ao todo, são 8 conjuntos variando de 1 até 8 cargas. O parâmetro da carga  $a$  está definido conforme a Equação 4.2.

$$A = \{a \in \mathbb{N}^* \mid 1 \leq a \leq 8\} \quad (4.2)$$

Os cenários estocásticos são aplicados no consumo fixo, geração e preço spot. Logo, o cenário  $h$  está definido conforme a Equação 4.3.

$$H = \{h \in \mathbb{N}^* \mid 1 \leq h \leq N\} \quad (4.3)$$

As cargas utilizadas possuem um tempo de funcionamento específico no dia, por exemplo, oito instantes de 15 minutos que equivalem a 2 horas de funcionamento. Além disso, o usuário pode adicionar uma janela de tempo para que a carga funcione apenas em um janela específica de horário do dia. Por fim, o usuário pode enviar para o sistema um horário desejado para que a carga funcione, dessa forma a carga iniciando no momento desejado, significa que o conforto é maximizado. O conforto definido neste trabalho são diferenças entre os ETOs do momento que um carga inicia seu processo e o momento desejado. Sabe-se que uma dada carga tem um tempo de funcionamento ( $t_{funcionamento}$ ), uma janela de tempo ( $t_{inicial}$  e  $t_{final}$ ) em que seu funcionamento é permitido e um tempo desejado ( $t_{desejado}$ ). Os valores adotados estão disponíveis na Tabela 5. Logo, respectivamente, as Equações (4.4),(4.5), (4.6) e (4.7) são representadas:

$$A_{t_{funcionamento}} = \{a_{t_{funcionamento}} \in \mathbb{N} \mid 0 \leq a_{t_{funcionamento}} \leq 95\} \quad (4.4)$$

em que  $a_{t_{funcionamento}}$  são os valores de ETOs de funcionamento para cada carga que variam entre 0 e 95 e  $A_{t_{funcionamento}}$  é o conjunto desses valores.

$$A_{t_{inicial}} = \{a_{t_{inicial}} \in \mathbb{N} \mid 0 \leq a_{t_{inicial}} \leq 95\} \quad (4.5)$$

em que  $a_{t_{inicial}}$  são os valores de ETOs da janela inicial para cada carga que variam entre 0 e 95 e  $A_{t_{inicial}}$  é o conjunto desses valores.

$$A_{t_{final}} = \{a_{t_{final}} \in \mathbb{N} \mid 0 \leq a_{t_{final}} \leq 95\} \quad (4.6)$$

em que  $a_{t_{final}}$  são os valores de ETOs da janela final para cada carga que variam entre 0 e 95 e  $A_{t_{final}}$  é o conjunto desses valores.

$$A_{t_{desejado}} = \{a_{t_{desejado}} \in \mathbb{N} \mid 0 \leq a_{t_{desejado}} \leq 95\} \quad (4.7)$$

em que  $a_{t_{desejado}}$  são os valores de ETOs desejados para cada carga que variam entre 0 e 95 e  $A_{t_{desejado}}$  é o conjunto desses valores.

Ademais, as cargas possuem uma potência ativa (kW) constante durante todos os ETOs de funcionamento associadas a cada uma das cargas. Os valores também estão disponíveis na Tabela 5. O parâmetro da potência está definido na Equação (4.8)

$$P_a = p_a \in \mathbb{R}_+^* \mid p_a \in \{0,6; 1,5; 4,0; 0,3; 1,5; 2,0; 1,5; 1,0\} \quad (4.8)$$

Na Tabela 5 são apresentadas os tipos de cargas utilizadas, além das potências ( $P_a$ ), quantidade de ETOs de funcionamento diário ( $a_{t_{funcionamento}}$ ), ETO inicial de funcionamento ( $a_{t_{inicial}}$ ), ETO desejado de funcionamento ( $a_{t_{desejado}}$ ) e ETO final de funcionamento ( $a_{t_{final}}$ ). A adoção desses valores foi arbitrária.

Tabela 5 – Definições das cargas

<b>Cargas</b>	$P_a(kW)$	$a_{t_{funcionamento}}$	$a_{t_{inicial}}$	$a_{t_{desejado}}$	$a_{t_{final}}$
Maquina de Lavar	0,6	8	8	32	72
Forno Elétrico	1,5	4	40	48	64
Aquecedor	4	1	20	24	28
Lavadora de pratos	0,3	4	72	84	92
Ar-condicionado1 (AC1)	1,5	12	40	64	80
Ar-condicionado2 (AC2)	2	20	32	68	92
Ar-condicionado3 (AC3)	1,5	32	8	8	80
Robô Aspirador	1	12	4	72	88

Fonte: Próprio autor.

Na Tabela 6 estão apresentados os 8 conjuntos de cargas utilizados nas simulações. Cada conjunto foi submetido a análises para avaliar a performance frente à utilização de diferentes regras para a resposta da demanda. Importante mencionar que o conjunto seguinte permanece com as mesmas cargas do conjunto anterior e tem a adição de uma nova carga.

Para a modelagem da bateria foram definidos parâmetros referentes ao seu funcionamento. A Equação (4.9) define a quantidade máxima de descarga da bateria, já a Equação (4.10) parametriza a quantidade máxima de carga da bateria. A Equação (4.11) define o limite

Tabela 6 – Conjunto de cargas

Conjunto	Carga 1	Carga 2	Carga 3	Carga 4	Carga 5	Carga 6	Carga 7	Carga 8
1	Maquina de Lavar							
2	Maquina de Lavar	Forno Elétrico						
3	Maquina de Lavar	Forno Elétrico	Aquecedor					
4	Maquina de Lavar	Forno Elétrico	Aquecedor	Lavadora de pratos				
5	Maquina de Lavar	Forno Elétrico	Aquecedor	Lavadora de pratos	AC1			
6	Maquina de Lavar	Forno Elétrico	Aquecedor	Lavadora de pratos	AC1	AC2		
7	Maquina de Lavar	Forno Elétrico	Aquecedor	Lavadora de pratos	AC1	AC2	AC3	
8	Maquina de Lavar	Forno Elétrico	Aquecedor	Lavadora de pratos	AC1	AC2	AC3	Robô Aspirador

Fonte: Próprio autor.

mínimo do *State of Charge* (SOC), enquanto a Equação (4.12) define o limite máximo. O SOC é o estado atual de carga da bateria.

$$p_{ESS_{max}^-} = 2 \quad (4.9)$$

em que  $p_{ESS_{max}^-}$  é a potência máxima de descarga da bateria em kW.

$$p_{ESS_{max}^+} = 2 \quad (4.10)$$

em que  $p_{ESS_{max}^+}$  é a potência máxima de carga da bateria em kW.

$$p_{SOC_{min}} = 1 \quad (4.11)$$

em que  $p_{SOC_{min}}$  é o limite mínimo de carga da bateria em kWh.

$$p_{SOC_{max}} = 10 \quad (4.12)$$

em que  $p_{SOC_{max}}$  é o limite máximo de carga da bateria em kWh.

O valor tarifário da energia comprada no mercado bilateral para este trabalho é conhecido e sua definição consta na Equação (4.13), a sua unidade é em Euro por Quilowatt-hora (EUR/kWh).

$$pr_{bilateral} = 0.038 \quad (4.13)$$

em que  $pr_{bilateral}$  é a tarifa do mercado bilateral.

Por fim, são apresentados os parâmetros com estocasticidade, ou seja, aqueles parâmetros conhecidos, e marcados por incertezas. Na Equação (4.14) mostra-se a inicialização

do preço de mercado *spot* e na Equação (4.15) mostra-se o início da potência líquida, valor resultante da subtração da potência da carga fixa com a geração. Os valores são inicializados em uma matriz, em que a primeira coluna representa o instante de tempo  $t$  que varia de 0 a 95 ETO e a segunda coluna é iniciado com valor 0, porém, após o tratamento da estocasticidade, são atribuídos novos valores.

$$pr_{spot}(t, h) \in \mathbb{R} \quad \forall t \in T \quad \forall h \in H \quad (4.14)$$

em que  $pr_{spot}(t, h)$  é a tarifa do mercado spot que varia ao longo do tempo  $t$  em um cenário  $h$ . A sua unidade é Euro por Quilowatt-hora (EUR/kWh).

$$P_{liquida}(t, h) \in \mathbb{R} \quad \forall t \in T \quad \forall h \in H \quad (4.15)$$

em que  $P_{liquida}(t)$  é a potência líquida que varia ao longo do tempo  $t$  em um cenário  $h$ . A sua unidade é kWh.

### 4.3.2 Variáveis

A bateria possui momentos de carga e descarga. Na Equação (4.16) é apresentada a variável  $x_{ESS+}(t)$  que, quando assume valor unitário, demonstra carregamento e valor 0 sinaliza que não está carregando. Já a Equação (4.17) é apresentada a variável  $x_{ESS-}(t)$  que sinaliza descarregamento com valor unitário e quando não está descarregando com valor igual a 0. Ambas são definidas como variáveis binárias.

$$x_{ESS+}(t) \in \{0, 1\}, \quad \forall t \in T \quad (4.16)$$

em que  $x_{ESS+}(t)$  demonstra se a bateria está carregando ou não em um tempo  $t$ .

$$x_{ESS-}(t) \in \{0, 1\}, \quad \forall t \in T \quad (4.17)$$

em que  $x_{ESS-}(t)$  demonstra se a bateria está descarregando ou não em um tempo  $t$ .

A potência de carga da bateria é definida conforme a Equação (4.18). A potência de descarga é similar a de carga e está definida como a Equação (4.19). Para finalizar a modelagem

das variáveis da bateria, a Equação (4.20) apresenta a caracterização do SOC da bateria, ou seja, a quantidade de carga em um instante de tempo  $t$ . As variáveis são definidas como reais não negativas.

$$0 \leq p_{ESS+}(t) \leq 2, \quad \forall t \in T \quad (4.18)$$

em que  $p_{ESS+}(t)$  refere-se a potência de carga da bateria em um tempo  $t$ .

$$0 \leq p_{ESS-}(t) \leq 2, \quad \forall t \in T \quad (4.19)$$

em que  $p_{ESS-}(t)$  refere-se a potência de descarga da bateria em um tempo  $t$ .

$$p_{SOC_{min}} \leq p_{SOC}(t) \leq p_{SOC_{max}}, \quad \forall t \in T \quad (4.20)$$

em que  $p_{SOC}(t)$  refere-se ao estado de carga da bateria em um tempo  $t$ .

A quantidade de energia comprada no mercado bilateral é representada na Equação (4.21), enquanto a quantidade comercializada no mercado *spot* está definida na Equação (4.22). O limite inferior da comercialização no mercado bilateral significa que não é possível vender energia, enquanto há um teto de 10 kW-15min de compra, valor este definido como parâmetro inicial da estocasticidade. No mercado *spot* há transação de compra e venda de energia, dessa forma, o conjunto dos valores pertence aos reais.

$$0 \leq p_{bilateral}(t) \leq 10, \quad \forall t \in T \quad (4.21)$$

em que  $p_{bilateral}(t)$  refere-se a potência adquirida no mercado bilateral em um tempo  $t$ .

$$p_{spot}(t) \in \mathbb{R}, \quad \forall t \in T \quad (4.22)$$

em que  $p_{spot}(t)$  refere-se a potência comercializada no mercado *spot* em um tempo  $t$ .

Para a resposta da demanda, 3 variáveis serão definidas. A primeira é formulada na Equação (4.23) e informa quando uma carga  $a$  está ligada em um instante de tempo  $t$ . A segunda refere-se ao instante de tempo  $t$  que a carga  $a$  foi ligada e está definida na Equação (4.24). A

terceira refere-se ao instante de tempo  $t$  em que a carga  $a$  foi desligada e está definida na Equação (4.25).

$$I(a,t) \in \{0,1\}, \quad \forall a \in A, \forall t \in T \quad (4.23)$$

em que  $I(a,t)$  refere-se a uma carga  $a$  está ligada ou desligada em um tempo  $t$ .

$$I_{inicio}(a,t) \in \{0,1\}, \quad \forall a \in A, \forall t \in T \quad (4.24)$$

em que  $I_{inicio}(a,t)$  refere-se a uma carga  $a$  foi ligada ou não em um tempo  $t$ .

$$I_{fim}(a,t) \in \{0,1\}, \quad \forall a \in A, \forall t \in T \quad (4.25)$$

em que  $I_{fim}(a,t)$  refere-se a uma carga  $a$  foi desligada ou não em um tempo  $t$ .

Para o conforto, são definidas 3 variáveis. O conforto é definido como a diferença do tempo em que a carga foi iniciada ( $t_{inicial}$ ) e o tempo desejado ( $t_{desejado}$ ) pelo consumidor. A solução ideal seria coletar o módulo da diferença entre o ( $t_{desejado}$ ) e ( $t_{inicial}$ ), porém não é possível utilizar a função de módulo por resultar em não linearidade. Para isso, a equação do módulo foi separada em duas, de tal forma que a primeira variável representada na Equação (4.26) recebe o valor da subtração entre o instante  $t$  de início de uma carga  $a$  e o valor desejado de início oferecido pelo usuário. A segunda variável é similar a primeira variável, porém ela capta a diferença negativa e sua definição está na Equação (4.27). A última variável representa o instante que a carga iniciou a operação na Equação (4.28), a sua diferença para a Equação (4.24) é que uma capta o valor inteiro do instante no qual a carga deu início (Ex: 56) e a outra representa o valor binário de quando a carga iniciou o processo (Ex: 1 no instante  $t = 56$ ).

$$I_{a+}(a) \in \mathbb{Z}^*, \quad \forall a \in A \quad (4.26)$$

em que  $I_{a+}(a)$  refere-se a parcela positiva entre a diferença do tempo desejado e tempo de inicio da carga  $a$ .

$$I_{a-}(a) \in \mathbb{Z}^*, \quad \forall a \in A \quad (4.27)$$

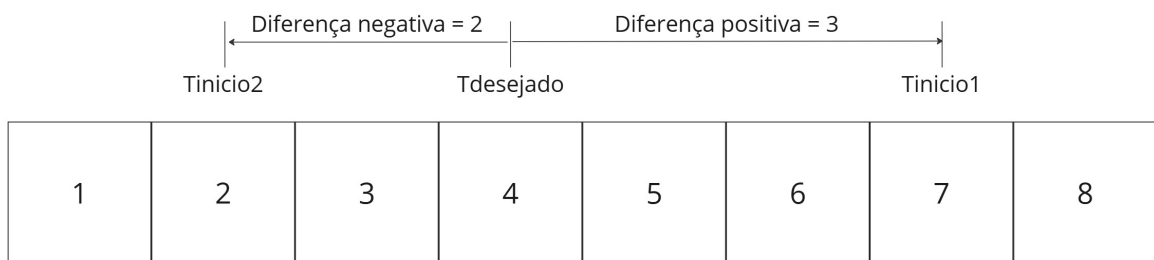
em que  $I_{a-}(a)$  refere-se a parcela negativa entre a diferença do tempo desejado e tempo de início da carga  $a$ .

$$I_{a_{real}}(a) \in \mathbb{Z}^*, \quad \forall a \in A \quad (4.28)$$

em que  $I_{a_{real}}(a)$  refere-se ao ETO de funcionamento que a carga  $a$  iniciou.

Na Figura 7 é apresentada uma forma gráfica da implementação das equações (4.26) e (4.27).

Figura 7 – Diferença positiva e negativa



Fonte: Próprio autor.

Trazendo como exemplo duas cargas com tempos de início diferentes, mas com o mesmo tempo desejado, tem-se que uma carga recebe valor dois na diferença negativa e a outra carga recebe valor 3 na diferença positiva. A soma do desconforto das duas cargas é cinco, pois as variáveis acima captaram a diferença de forma similar ao módulo, logo o valor é somado e não subtraído.

### 4.3.3 Expressões

Na Equação (4.29) é definida a demanda das cargas deslocáveis como:

$$DD = \sum_{a \in A} \sum_{t \in T} (p_a * I(a, t)) \quad (4.29)$$

Em que  $DD$  é a demanda das cargas deslocáveis, sendo resultante da multiplicação da potência das cargas deslocáveis  $a$  com os instantes  $t$  que estão ligadas.

Em seguida, a Equação (4.30) define a demanda total como:

$$DT = \sum_{a \in A} \sum_{t \in T} ((p_a * I(a, t) + P_{liquida}(t)) \quad (4.30)$$

em que  $DT$  é a demanda total, sendo a soma da demanda das cargas deslocáveis com a demanda das cargas não deslocáveis.

Além disso, é definido na Equação (4.31) a expressão que reflete o parâmetro do custo bilateral que é utilizado na modelagem estocástica como:

$$ST = pr_{bilateral} \quad (4.31)$$

em que  $ST$  é o parâmetro inicial da modelagem estocástica referente ao preço do mercado bilateral.

Para normalizar o termo do conforto na função objetivo, foi calculado o pior cenário de ativação de uma carga. Em seguida, é aplicado o somatório para todas as cargas contidas na simulação. A modelagem está definida na Equação (4.32) como:

$$PC = \sum_{a=1}^A (a_{t_{final}}(a) - a_{t_{inicial}}(a) - a_{t_{funcionamento}}(a)) \quad (4.32)$$

em que  $PC$  é o pior cenário de ativação das cargas para o conjunto de simulação atual.

Por fim, para normalizar o termo do custo na função objetivo, foi calculado o pior cenário de custo considerando o maior valor do preço *spot*. A modelagem está definida na Equação (4.33) como:

$$MC = DT \cdot pr_{spotmax} \quad (4.33)$$

em que  $MC$  é o pior cenário de custo e  $pr_{spotmax}$  é o maior valor do preço *spot* entre todos os cenários.

#### 4.3.4 Função Objetivo

A função objetivo é uma equação que é maximizada ou minimizada. No caso deste trabalho, a função objetivo será minimizada para o custo diário de energia elétrica e desconforto. O conforto é marcado pela soma das Equações (4.27) e (4.26). Para o custo de energia elétrica, é feita a multiplicação da quantidade de energia comercializada pela tarifa dos mercados bilateral e *spot*. Sendo assim, a Equação (4.34) é definida como:

$$CT = \left[ \sum_{t=1}^T (p_{bilateral}(t) \cdot pr_{bilateral}) \cdot \Delta t + \sum_{z=1}^{N_z} \sum_{t=1}^T (p_{spot}(t) \cdot pr_{spot}(t)) * \pi(z) \cdot \Delta t \right] \quad (4.34)$$

em que  $CT$  é o custo total,  $\Delta t$  é igual a 0.25, ou seja, um quarto de hora e  $\pi(z)$  é a probabilidade de ocorrência dos cenários.

Na Equação (4.35) é definido o desconforto como:

$$DC = \sum_{a \in A} (I_{a+}(a) + I_{a-}(a)) \quad (4.35)$$

em que  $DC$  é o desconforto.

A Equação (4.36) a ser minimizada é definida como:

$$\min F_{obj} = \alpha \cdot \frac{CT}{MC} + (1 - \alpha) \cdot \frac{DC}{PC} \quad (4.36)$$

em que  $F_{obj}$  é a expressão a ser minimizada e sem unidade definida, pois soma-se custo com tempo. E  $\alpha$  é uma variável peso que varia entre 0 e 1.

#### 4.3.5 Restrições

As restrições são imposições que limitam a abrangência da solução. Dessa forma, é necessário que as restrições sejam bem definidas para alcançar o resultado desejado.

A bateria possui um conjunto de restrições que limita e/ou caracteriza o seu funcionamento. Na Equação (4.37) restringe que a bateria não pode carregar e descarregar no mesmo instante de tempo  $t$ , porém permite a sua inércia de não utilização. Na Equação (4.38) restringe que a potência de descarregamento tem que ser menor ou igual a potência máxima de descarregamento no instante de tempo  $t$  em que a bateria está descarregando. A Equação (4.39) é similar a anterior, porém define que a potência de carregamento deve ser menor ou igual a potência máxima de carregamento no instante de tempo  $t$  em que a bateria está carregando. Para definir o SOC inicial da bateria, a Equação (4.40) impõe um valor de 20% da carga máxima da bateria. Para tanto, a Equação (4.41) define o quantitativo de carga armazenada na bateria em um instante  $t$ .

$$x_{ESS+}(t) + x_{ESS-}(t) \leq 1 \quad \forall t \in T \quad (4.37)$$

$$p_{ESS-}(t) \leq P_{ESS_{max}^-}(t) \cdot x_{ESS-}(t) \quad \forall t \in T \quad (4.38)$$

$$P_{ESS^+}(t) \leq P_{ESS_{max}^+}(t) \cdot x_{ESS^+}(t) \quad \forall t \in T \quad (4.39)$$

$$P_{SOC}(0) = 0.2 \cdot P_{SOC_{max}} \quad (4.40)$$

$$P_{SOC}(t) = P_{SOC}(t-1) + (x_{ESS^+}(t) - x_{ESS^-}(t)) \cdot 0.25 \quad \forall t \in T \quad (4.41)$$

Para delimitar o funcionamento do mercado foram definidas 4 restrições. A Equação (4.42) impõe que a potência comprada no mercado bilateral seja maior que 0, sendo assim não é possível vender energia nesse mercado. A Equação (4.43) diz que a soma das potências de ambos os mercados deve ser igual ou superior à demanda líquida total da residência. A Equação (4.44) limita que a energia pode ser vendida no mercado *spot* se a produção superar o consumo. Já a Equação (4.45) diz que a energia comprada no mercado bilateral não pode ser vendida no mercado *spot* no mesmo instante de tempo.

$$P_{bilateral}(t) > 0 \quad \forall t \in T \quad (4.42)$$

$$P_{spot}(t) + P_{bilateral}(t) \geq DT(t) + (P_{ESS^+}(t) + P_{ESS^-}(t)) \quad \forall t \in T \quad (4.43)$$

$$P_{spot}(t) = DT(t) + (P_{ESS^+}(t) + P_{ESS^-}(t)) \mid DT(t) + (P_{ESS^+}(t) + P_{ESS^-}(t)) \leq 0 \quad \forall t \in T \quad (4.44)$$

$$P_{spot}(t) \geq 0 \mid DT(t) + (P_{ESS^+}(t) + P_{ESS^-}(t)) \geq 0 \quad \forall t \in T \quad (4.45)$$

Para a Resposta da Demanda existem funcionalidades como: tempo de funcionamento, janela de funcionamento, funcionamento ininterrupto e conforto. A primeira e a mais básica regra para a aplicação da RD é a utilização do tempo de funcionamento e está definida na Equação (4.46). Ela diz que a carga  $a$  deve funcionar pelo tempo estabelecido  $t$  previamente,

ou seja, o somatório dos ETOs que a carga está ativa deve ser igual ao tempo previsto de funcionamento.

$$\sum_{a \in A} \sum_{t \in T} I(a, t) = a_{t_{funcionamento}} \quad (4.46)$$

A segunda funcionalidade refere-se à criação de uma janela de tempo em que uma carga  $a$  deve funcionar, ou seja, vai limitar os possíveis ETOs de funcionamento dentro de uma janela de tempo inicial e final. A Equação (4.47) define essa funcionalidade.

$$a_{t_{inicial}} \leq I(a, t) \leq a_{t_{final}} \quad (4.47)$$

A terceira funcionalidade representa que, após o início do processo de funcionamento da carga  $a$ , ele deve concluir de forma ininterrupta, ou seja, só pode ter uma partida e um desligamento por carga no dia. A Equação (4.48) representa que a carga só pode estar ligada ou desligada no mesmo instante de tempo  $t$ . A Equação (4.49) correlaciona as variáveis de início e fim com o tempo de funcionamento de cada carga. A Equação (4.50) é uma função auxiliar que restringe o tempo de operação conforme a janela desejada pelo usuário. A Equação (4.51) é um conjunto de regras que sintetiza que a quantidade de ETOs de funcionamento deve ser igual ou maior que o tempo de funcionamento previsto para cada carga multiplicado pelo momento em que a carga iniciou o processo.

$$I_{inicio}(a, t) + I_{fim}(a, t) \leq 1 \quad (4.48)$$

$$I_{inicio}(a, t) - I_{fim}(a, t) = I(a, t) - I(a, t - 1) \quad (4.49)$$

$$aux_a = (a_{t_{final}} - a_{t_{funcionamento}} + 2) - a_{t_{inicial}} \quad (4.50)$$

$$\sum_{k \in aux_a}^{k+a_{t_{funcionamento}}} I(a, t) \geq a_{t_{funcionamento}} \cdot I_{inicio}(a, t) \quad (4.51)$$

A última funcionalidade implementada no modelo da RD neste trabalho é o conforto. A Equação (4.52) define que a diferença entre as variáveis da diferença positiva e negativa é igual a diferença do momento que uma carga teve início e o tempo desejado. A restrição na Equação (4.53) mostra que a variável responsável pela diferença positiva não assumirá valores negativos. A Equação (4.54) é similar a anterior, porém mostra que a variável responsável pela diferença negativa não assumirá valores negativos. Por fim, a Equação (4.55) é uma restrição que captura o instante  $t$  que a carga deu início e armazena-a como um número inteiro.

$$I_{a+}(a) - I_{a-}(a) = I_{a_{real}}(a) - a_{t_{desejado}}(a) \quad (4.52)$$

$$I_{a+}(a) \geq 0 \quad (4.53)$$

$$I_{a-}(a) \geq 0 \quad (4.54)$$

$$I_{a_{real}}(a) = \sum_t^{96} t \cdot I_{início}(a, t) \quad (4.55)$$

## 4.4 Medidas de avaliação

### 4.4.1 Desempenho da rede

Para avaliar a influência de uma residência com um sistema de gerenciamento de energia residencial com programa de resposta da demanda na rede elétrica, são calculados os parâmetros de demanda e fator de carga que são definidos em Kersting and Kerestes (2022).

A demanda máxima de kW em 15 minutos é o maior valor em kW dentre os 96 ETOs obtidos na simulação. Na Equação 4.56 é definido como esse valor é obtido:

$$D_{max_{15min}} = Max DT \quad (4.56)$$

A demanda média de kW em 15 minutos é a soma das demandas dos 96 ETOs dividida por 96, conforme mostra a Equação 4.57:

$$D_{avg15min} = \frac{(\sum_t^{96} DT)}{96} \quad (4.57)$$

O Fator de Carga (FC) é definido como a razão entre a demanda média e a demanda máxima (Kersting; Kerestes, 2022). O FC está definido na Equação 4.58:

$$FC = \frac{D_{avg15min}}{D_{max15min}} \quad (4.58)$$

Similar ao FC, porém sendo o inverso do seu valor, o *Peak-to-Average Ratio* (PAR) é um recurso constantemente utilizado na avaliação de programas de RD. Com o valor unitário, significa que a demanda média é igual à demanda máxima; dessa forma, a curva de carga é constante e, conseqüentemente, melhor é a utilização dos recursos da rede. Na Equação 4.59 é definido o PAR:

$$PAR = \frac{D_{max15min}}{D_{avg15min}} \quad (4.59)$$

#### 4.4.2 Simulação

Como a otimização MILP é solucionada pelo CPLEX através do método *branch & cut*, logo há um tempo envolvido neste processo. O tempo de simulação é um fator decisório para a implementação em uma solução real. Dessa forma, foi utilizada a matriz de correlação entre os parâmetros de entrada e a saída (tempo de simulação) para avaliar a correlação com o resultado final. São analisados a correlação entre as variáveis de entrada e saída, ou seja, um método de análise bivariada, o resultado desse método retorna um número entre -1 e 1. De uma forma simplificada, o quanto mais próximo de 1 significa que as duas variáveis crescem proporcionalmente, já com valores próximos de -1 significa que enquanto uma cresce a outra decresce. Por fim, valores próximos de 0 significam que as variáveis não possuem correlação uma com a outra, sendo assim o comportamento de uma não afeta a outra.

Para obter a matriz de correlação foi utilizada a função *corr* do *pandas* e o método usado é o coeficiente de correlação de Pearson cuja Equação (4.60) é representada por:

$$\rho_{X,Y} = \frac{cov(X,Y)}{\sigma_x \sigma_y} \quad (4.60)$$

em que  $\rho_{X,Y}$  é o coeficiente de correlação,  $cov(X, Y)$  é a covariância e o  $\sigma$  é o desvio padrão para cada variável. A covariância é definida na Equação (4.61) por:

$$\text{cov}(X, Y) = \frac{E[(X - \bar{x})(Y - \bar{y})]}{N - 1} \quad (4.61)$$

em que  $X$  e  $Y$  são valores de duas variáveis quaisquer,  $\bar{x}$  e  $\bar{y}$  são as respectivas médias de cada variável e  $N$  é a quantidade de elementos.

#### **4.5 Considerações**

Neste capítulo foram apresentadas as informações relativas ao método de otimização, linguagem de programação, solucionador, os dados de entradas, a formulação matemática da otimização por meio dos parâmetros, variáveis, expressões, função objetivo e restrições, além de apresentar as ferramentas de avaliação do desempenho da rede e da simulação do modelo.

## 5 RESULTADOS

Para a simulação foi utilizado um computador pessoal no formato de *laptop* com um processador i5 11ª geração 2,70 GHZ, 32 GB de RAM, GTX 1650 4GB, SSD de 512 GB com carregamento de bateria ativo. Os resultados provenientes das simulações foram gerados através de funções específicas do *Pyomo* como o *Model.pprint()* que imprime o relatório da formulação matemática e estados das variáveis no terminal, *pyo.value()* que pega valores específicos e o *tee* habilitado dentro da função *solve\_ef* do *rappier* para imprimir no terminal o relatório do CPLEX.

No total, foram realizadas 40 simulações diferentes, para cada conjunto de regra e de carga. Na Tabela 7 são mostradas as nomenclaturas utilizadas para cada conjunto de regras e cargas utilizadas nas simulações. Por exemplo, o conjunto R3C4 significa que foram utilizadas 4 cargas para o conjunto de regras 3.

Tabela 7 – Nomenclatura para conjunto de regras e cargas

Conjuntos	Cargas 1	Cargas 2	Cargas 3	Cargas 4	Cargas 5	Cargas 6	Cargas 7	Cargas 8
Regras 1	R1C1	R1C2	R1C3	R1C4	R1C5	R1C6	R1C7	R1C8
Regras 2	R2C1	R2C2	R2C3	R2C4	R2C5	R2C6	R2C7	R2C8
Regras 3	R3C1	R3C2	R3C3	R3C4	R3C5	R3C6	R3C7	R3C8
Regras 4	R4C1	R4C2	R4C3	R4C4	R4C5	R4C6	R4C7	R4C8
Regras 5	R5C1	R5C2	R5C3	R5C4	R5C5	R5C6	R5C7	R5C8

Fonte: Próprio autor.

Os conjuntos de cargas utilizados são os mesmos da Tabela 6, assim, a cada simulação foi incrementada uma carga com as atribuições de valores previstos na Tabela 5.

Para o conjunto de regras foram utilizadas 5 situações.

1. Regra 1: Cargas operando com interrupções, sem uma delimitação de uma janela de tempo de operação e sem conforto. Equivale a todas as equações da Seção 4.3, menos as Equações (4.35), (4.47), (4.48), (4.49), (4.50), (4.51), (4.52), (4.53), (4.54), (4.55) e  $\alpha = 1$ ;
2. Regra 2: Cargas operando com interrupções e sem conforto. Equivale a todas as equações da Seção 4.3, menos as Equações (4.35), (4.48), (4.49), (4.50), (4.51), (4.52), (4.53), (4.54), (4.55) e  $\alpha = 1$ ;
3. Regra 3: Cargas operando sem interrupções e sem conforto. Equivale a todas as equações da Seção 4.3, menos as Equações (4.35), (4.52), (4.53), (4.54), (4.55) e  $\alpha = 1$ ;
4. Regra 4: Cargas operando sem interrupções e com ponderação no custo e conforto. Equivale a todas as equações da Seção 4.3 com  $\alpha = 0,5$ ;

5. Regra 5: Cargas operando sem interrupções e conforto maximizado. Equivale a todas as equações da Seção 4.3 com  $\alpha = 0$ .

### 5.1 Tempo de Resposta

Para captar as informações do tempo de processamento da solução foi utilizado o *tee* habilitado dentro da função *solve\_ef* do *rappier* para imprimir no terminal o relatório do CPLEX. Além disso, outros parâmetros foram captados e estão dispostos na Figura 8. Para cada coluna foi adicionada uma escala de cor com intuito de facilitar a leitura da tabela, sendo que a cor verde indica que são valores menores, amarelo valores intermediários e vermelho para valores maiores. De acordo com IBM Corporation (2022), a coluna de “Var” representa a quantidade de variáveis do modelo, “Obj NZ” representa a quantidade coeficientes não nulos na função objetivo, “RL” representa a quantidade de restrições lineares do modelo, “R NZ” representa a quantidade de coeficientes das restrições que são diferentes de zero, “RHS NZ” mostra a quantidade de valores não nulos que ficam no lado da direita das restrições e “TS (s)” significa o tempo de solução em segundos. Esse indicadores mostram a complexidade do problema e eles variam de acordo com as mudanças de conjuntos de regras e cargas.

Nota-se que o tempo de solução não possui uma regra clara que indica qual variável pondera mais para o seu crescimento. Porém, há um acréscimo generalizado nos parâmetros de entrada conforme aumenta a quantidade de cargas e de regras. O conjunto de regras quatro com oito cargas (R4C8) é o que possui os maiores valores de parâmetros de entrada, isso é decorrente da função objetivo que contempla tanto custo quanto conforto, logo todas as equações estão ativas. Os maiores de tempo de simulação aconteceram com as regras três e quatro para o conjunto de cargas oito, o que corrobora com o maior quantitativos de parâmetros de entrada do CPLEX. A média dos tempos de solução das 40 simulações é de 96,77 segundos, ou seja, um tempo estritamente factível para implementação e com possibilidade de redução no tempo de simulação em computadores mais robustos.

Na Figura 8 existe uma correlação clara entre a relação das variáveis de entrada com a saída, pois conjuntos com mais volume de dados de entrada obteve um maior tempo de resposta. O tempo de solução superior para os casos R3C6, R3C7, R3C8 e R4C8 pode indicar uma saturação do modelo devido a quantidade dos parâmetros de entrada, necessitando assim um computador mais robusto ou substituir a otimização por outros modelos. Na Figura 9 é mostrado a análise bivariada de correlação entre os preditores de entrada e saída. Todas as variáveis de


Figura 8 – Parâmetros de entrada e saída do CPLEX

Conjuntos	Var	Obj NZ	RL	R NZ	RHS NZ	TS (s)
R1C1	7997	1739	6967	21103	1912	0,17
R1C2	9743	1739	7012	23905	1930	0,26
R1C3	11489	1739	7057	26707	1948	0,3
R1C4	13235	1739	7102	29509	1966	0,31
R1C5	14981	1739	7147	32311	1984	0,34
R1C6	16727	1739	7192	35113	2002	0,41
R1C7	18473	1739	7237	37915	2020	0,42
R1C8	20219	1739	7282	40717	2038	0,45
R2C1	7997	1739	7831	21967	2497	0,17
R2C2	9743	1739	8740	25633	2740	0,22
R2C3	11489	1739	9649	29299	2839	1,66
R2C4	13235	1739	10558	32965	3046	0,31
R2C5	14981	1739	11467	36631	3433	0,56
R2C6	16727	1739	12376	40297	4000	1,25
R2C7	18473	1739	13285	43963	4675	4,83
R2C8	20219	1739	14194	47629	5458	6,38
R3C1	8870	1739	10072	31813	3361	0,31
R3C2	11489	1739	12898	41617	4468	0,38
R3C3	14108	1739	15607	50593	5431	1,44
R3C4	16727	1739	18397	60217	6502	1,08
R3C5	19346	1739	21295	72541	7753	3,61
R3C6	21965	1739	24301	89293	9184	140,92
R3C7	24584	1739	27307	110581	10723	637,33
R3C8	27203	1739	30601	128053	12370	1670,47
R4C1	8870	1757	10072	31831	3361	7,69
R4C2	11489	1775	12898	41653	4468	6,92
R4C3	14108	1793	15607	50647	5431	7,45
R4C4	16727	1811	18397	60289	6502	9,14
R4C5	19346	1829	21295	72631	7753	27,94
R4C6	21965	1847	24301	89401	9184	38,39
R4C7	24584	1865	27307	110707	10723	96,98
R4C8	27203	1883	30601	128197	12370	1176,17
R5C1	8870	29	10072	30103	3361	0,59
R5C2	11489	47	12898	39925	4468	0,81
R5C3	14108	65	15607	48919	5431	0,75
R5C4	16727	83	18397	58561	6502	0,92
R5C5	19346	101	21295	70903	7753	1,24
R5C6	21965	119	24301	87673	9184	1,80
R5C7	24584	137	27307	108979	10723	7,41
R5C8	27203	155	30601	126469	12370	13,16

Fonte: Próprio autor.

entrada possuem correlação positiva com a saída, ou seja, ambos crescem. Todas as variáveis de entrada, menos objetivos não zeros possuem uma alta correlação entre si, ou seja, ambos crescem. O motivo por objetivos não zeros possuírem essa relação negativa com as outras variáveis de entrada é pelo fato de que no conjunto de regra cinco, o custo é retirado da equação quando  $\alpha = 0$ , assim há um menor quantitativo de expressões na função objetivo.

Figura 9 – Gráfico de calor com correlação




Fonte: Próprio autor.

## 5.2 Desempenho da Resposta da Demanda

Para entender melhor os resultados referentes ao desempenho da RD, é importante entender como os preços do mercado bilateral e *spot* se comportam para as simulações. Na Figura 10 é mostrado os custos tarifários de ambos os mercados. Como era esperado, a tarifa *spot* possui um comportamento variável ao longo do dia, enquanto a tarifa bilateral é um valor fixo. Interessante mencionar que, no comportamento dos preços, há uma parábola invertida no mercado *spot* por volta do meio-dia. Esse comportamento ocorre pela presença massiva da fonte de energia solar fotovoltaica no seu momento de pico no mercado *spot*.

Para avaliar o desempenho da RD foram utilizados os dados provenientes das simulações pelas funções específicas do *Pyomo* como o *Model.pprint()* que imprime o relatório da formulação matemática e estados das variáveis no terminal, *pyo.value()* que pegam valores específicos.

Na Figura 11 é mostrada a demanda total, ou seja, a soma da demanda fixa, da demanda deslocável e o uso do sistema de armazenamento de energia. Por exemplo, na Figura

Figura 10 – Preços tarifários do mercado *spot* e bilateral

Fonte: Próprio autor.

11(a) são mostradas as curvas de demanda ao longo do tempo para uma carga utilizando os 5 conjuntos de regras. Nota-se que a regra 1, que possui menos restrições de funcionalidades da RD, possui uma alta demanda no começo e no final do dia justamente pelo baixo valor da tarifa *spot*, onde não há limite de energia para compra e venda. O comportamento da demanda total varia entre conjuntos de cargas e de regras. É possível verificar que a adição de regras faz com que o sistema de gerenciamento de energia readeque a demanda para satisfazer as restrições e a função objetivo. Além disso, há venda de energia nos momentos em que a demanda é negativa. Interessante mencionar que a presença do sistema de armazenamento de energia implica em uma utilização menor da rede nos horários de picos (17h-21h) comparado com outros momentos do dia.

Com a demanda dividida em 96 ETOs de 15 minutos cada, alguns parâmetros da rede elétrica como a demanda média e o FC são calculados na Tabela 8. Os valores são captados para diferentes conjuntos de cargas e regras.

Nota-se que para os quatro primeiros conjuntos de cargas para todos os conjuntos de regras possuem o valor de demanda total diário, porém para o conjunto de regras que o custo não

Tabela 8 – Parâmetros da RD na rede elétrica

<b>Conjuntos</b>	<b>DT (kW)</b>	<b><math>D_{avg15min}</math> (kW)</b>	<b><math>D_{max15min}</math> (kW)</b>	<b>FC</b>	<b>PAR</b>
R1C1	52,49	0,55	3,00	0,18	5,49
R2C1	52,49	0,55	3,09	0,18	5,65
R3C1	52,49	0,55	5,05	0,11	9,23
R4C1	52,49	0,55	3,05	0,18	5,58
R5C1	90,49	0,94	3,05	0,31	3,23
R1C2	58,49	0,61	3,26	0,19	5,35
R2C2	58,49	0,61	3,89	0,16	6,39
R3C2	58,49	0,61	3,89	0,16	6,39
R4C2	58,49	0,61	4,15	0,15	6,82
R5C2	96,49	1,01	3,05	0,33	3,03
R1C3	62,49	0,65	6,68	0,10	10,26
R2C3	62,49	0,65	4,09	0,16	6,28
R3C3	62,49	0,65	4,42	0,15	6,78
R4C3	62,49	0,65	3,52	0,19	5,40
R5C3	100,49	1,05	4,01	0,26	3,84
R1C4	63,69	0,66	7,38	0,09	11,13
R2C4	63,69	0,66	4,15	0,16	6,26
R3C4	63,69	0,66	4,07	0,16	6,14
R4C4	63,69	0,66	3,53	0,19	5,32
R5C4	101,69	1,06	4,01	0,26	3,79
R1C5	81,69	0,85	8,88	0,10	10,44
R2C5	81,69	0,85	5,39	0,16	6,34
R3C5	81,69	0,85	5,39	0,16	6,34
R4C5	81,69	0,85	4,15	0,20	4,88
R5C5	119,69	1,25	4,01	0,31	3,22
R1C6	121,69	1,27	10,48	0,12	8,27
R2C6	121,69	1,27	7,39	0,17	5,83
R3C6	121,69	1,27	5,58	0,23	4,40
R4C6	121,69	1,27	5,88	0,22	4,64
R5C6	123,69	1,29	4,91	0,26	3,81
R1C7	169,69	1,77	12,38	0,14	7,00
R2C7	169,69	1,77	8,89	0,20	5,03
R3C7	169,69	1,77	6,89	0,26	3,90
R4C7	169,69	1,77	5,51	0,32	3,12
R5C7	171,69	1,79	5,51	0,32	3,08
R1C8	181,69	1,89	12,98	0,15	6,86
R2C8	181,69	1,89	8,89	0,21	4,70
R3C8	181,69	1,89	6,89	0,27	3,64
R4C8	181,69	1,89	6,03	0,31	3,19
R5C8	219,69	2,29	5,91	0,39	2,58

Fonte: Próprio autor.

está presente, o resultado é diferente devido ao comportamento do sistema de armazenamento que está atrelado ao custo e não ao conforto. A demanda média de 15 minutos também possui o mesmo comportamento. A justificativa para esse comportamento é que o valor da demanda

média é a divisão da demanda total diária por 96. Para os valores de demanda máxima surge a diferença e isso é decorrente da mudança da curva de carga para cada conjunto de regra. Por exemplo, o conjunto de regras 1 possui cargas ativas no início e final do dia, fazendo com que esse indicador seja mais expressivo. Um detalhe importante, é que devido ao valor discrepante da demanda total diária para o conjunto de regras cinco, assim implica numa maior demanda média comparado com os outros cenários, logo ao realizar o cálculo da Fator de Carga e do *Peak-to-Average Ratio* ocasiona melhores indicadores para a rede elétrica. O FC é o inverso do PAR e é notável sua correlação ao observar o incremento de um e decréscimo de outro.

É interessante mostrar que a RD por si só não reduz o PAR, sendo que a RD pode aumentar esse indicador com cargas iniciando no mesmo horário, além de tarifas com valores baixos para incentivar o consumo. As regras utilizadas para a RD, por exemplo, o conjunto de regras 1, gera um efeito rebote devido ao remanejamento das cargas para momentos de baixos valores tarifários. Algumas alternativas para suavizar o PAR envolvem ter um agregador para gerenciar uma comunidade de energia e servir como uma segunda camada de otimização das cargas ou implementar o PAR como um fator a ser minimizado na função objetivo. Outro fator a ser mencionado diz respeito à função objetivo, pois existe uma soma entre unidades de medidas diferentes, uma é EUR/kWh e a outra é ETO de 15 minutos. Além disso, escalas de preço e tempo diferentes fazem com que o peso de um parâmetro seja irrelevante na função, logo a adição de mais outro fator e o seu tratamento inadequado podem gerar complicações no resultado esperado. No caso desta simulação, foi realizado uma normalização de ambos os parâmetros.

Quanto ao funcionamento das cargas, foram simulados os conjuntos de oito cargas para as 5 regras diferentes. O círculo preenchido significa que a carga está funcionando no intervalo de 15 minutos e o quadrado representa o tempo desejado, porém o conforto só está ativo nas duas últimas regras, sendo assim o tempo desejado nas três primeiras regras é meramente ilustrativo para indicar que não há tendência da carga minimizar o desconforto. Na Figura 12 é mostrado o funcionamento da primeira regra, sem uma janela de tempo específica para cada carga, funcionamento com interrupções e sem conforto.

Na Figura 13 é mostrado a adição da janela de tempo para cada carga, reduzindo assim as execuções no começo e no fim do dia para algumas delas. Nota-se uma preferência pelos momentos em que a tarifa *spot* é mais barata justamente para minimizar o custo.

Na Figura 14 é mostrado a adição da regra em que as cargas não podem ser interrompidas, logo o momento inicial de partida da carga deve ser o ótimo para a sequência de tempo em

que o equipamento estará funcionando. Nota-se que os equipamentos não funcionam no tempo desejado, pois não é o melhor cenário de redução de custos.

Na Figura 15 é mostrado todas as restrições e isso é notável com as cargas tendo início no tempo desejado, sem interrupções, com janela de tempo e tempo de funcionamento pré-estabelecido. Mesmo com um  $\alpha = 0,5$  mostra que todas as cargas tenderam para o tempo desejado. Mesmo com a normalização dos valores e utilizando um peso de 0,5 para ambos, nota-se que há uma preferência para não existir o deslocamento de cargas do seu horário desejado.

Na Figura 16 é mostrado todas as restrições e isso é notável com as cargas tendo início no tempo desejado, porém com um  $\alpha = 1$ , ou seja, conforto maximizado. As cargas tiveram início no mesmo tempo que o conjunto de regras anterior, porém com a ausência do custo acarreta impactos financeiros.

A análise da quantidade de energia executada como venda ou compra no mercado *spot* também foi verificada para diferentes conjuntos. Na Figura 17 mostra o compilado das potências comercializadas no mercado *spot*, em que, a Figura 17(c), por exemplo, há o quantitativo para o conjunto com 3 cargas com vendas em partes do dia, ausência de transações em momentos no quais o mercado bilateral é mais vantajoso, exceto para o conjunto de regras 5 que desempenha toda a sua compra/venda de energia no mercado *spot*, e um pico de energia transacionada para a Regra 1, pois as cargas se alocaram no período de menor preço. É importante mencionar que visando a redução de custos, é feita transação de energia no formato de venda em que a energia *spot* é mais cara e isso é decorrente do armazenamento de energia que permite essa compra em momentos com valores inferiores para vender com valores superiores, além das regras de mercado que permitem essas transações.

Ao analisar o mercado bilateral, é notado uma ação mais tímida de compra de energia e há períodos com ausência de transação. Os motivos são os momentos em que a energia *spot* é mais barata que a bilateral e não tem restrição de quantitativo para compra, já que o bilateral tem um teto de 10 kW. A Figura 18 expõe a quantidade de energia transacionada em cada situação. Tomando como exemplo a Figura 18(g), mostram-se 3 grandes momentos de compra de energia, além de que o conjunto de 7 cargas com o conjunto de regras 4 há uma expressividade de compra de energia na terceira onda marcada entre 15-20h, momento este em que várias cargas estão alocadas para funcionar em decorrência do conforto. Para o conjunto de regras 5, o mercado bilateral permaneceu com valor zerado para todos os casos e recorreu somente a compra no mercado *spot*.

O SOC da bateria também foi analisado nas circunstâncias similares aos outros parâmetros. Na Figura 19 contempla a energia armazenada. Por exemplo, na Figura 19(h) mostra a situação do armazenamento para as 8 cargas com diferentes conjuntos de regras. Para todos os conjuntos, exceto o conjunto de regra 5, há um perfil similar de armazenamento no começo do dia e utilização no resto do dia. Para essa exceção, o conjunto de bateria não performou adequadamente, pois como não há intenções de minimizar o custo e a energia proveniente do mercado *spot* não há limites inferiores e superiores, logo não foi necessário a bateria para estabelecer a potência necessária para as cargas funcionarem, porém esse comportamento impacta na demanda total diária e nos outros indicadores. Essas transações utilizando a bateria é importante para economizar dinheiro ao longo do dia.

Por fim, a Tabela 9 resume o custo total em unidades monetárias para cada uma das 40 simulações. Os valores financeiros coletados tem influência, mas não é o resultado direto da função objetivo e sim pela multiplicação do custo e potência comercializada em ambos os mercados, pois não seria possível captar o custo financeiro para o cenário em que o custo não é considerado na equação. O aumento das restrições que impedem o funcionamento livre das cargas aumenta o custo de energia, pois elas podem ser alocadas em condições de maior custo e isso é notado no aumento dos conjuntos das restrições. Nota-se que o custo de implementação do conforto aumenta o custo diário de energia. Mesmo o conjunto de regras 4 e 5 possuindo o mesmo momento de funcionamento das cargas deslocáveis há ainda uma diferença no custo diário, pois a minimização parcial do custo promove a utilização dos recursos do sistema de armazenamento e uma otimização do mercado de energia.

Tabela 9 – Custo acumulado entre os conjuntos de cargas e regras

<b>Conjuntos</b>	<b>R1 (EUR)</b>	<b>R2 (EUR)</b>	<b>R3 (EUR)</b>	<b>R4 (EUR)</b>	<b>R5 (EUR)</b>
C1	0,29	0,29	0,29	0,32	1,24
C2	0,32	0,35	0,35	0,37	1,29
C3	0,35	0,38	0,38	0,41	1,34
C4	0,36	0,39	0,39	0,42	1,34
C5	0,48	0,55	0,55	0,59	1,57
C6	0,76	0,89	0,90	0,96	1,75
C7	1,12	1,29	1,34	1,42	2,17
C8	1,20	1,38	1,42	1,53	2,54

Fonte: Próprio autor.

A Tabela 10 mostra a diferença percentual entre cada conjunto de regra com o pior caso (somente conforto). É observado que o conjunto de regras 1 possui um melhor rendimento

no custo financeiro com uma redução de 77% para uma carga e a menor redução foi de 35% para o conjunto de regras 4.


Tabela 10 – Diferença percentual entre conjuntos de cargas e regras

<b>Conjuntos</b>	<b>% (R1-R5)</b>	<b>% (R2-R5)</b>	<b>% (R3-R5)</b>	<b>% (R4-R5)</b>
C1	-77%	-76%	-76%	-74%
C2	-75%	-73%	-73%	-71%
C3	-74%	-71%	-71%	-69%
C4	-73%	-71%	-71%	-69%
C5	-69%	-65%	-65%	-62%
C6	-57%	-49%	-49%	-45%
C7	-49%	-40%	-38%	-35%
C8	-53%	-46%	-44%	-40%


Fonte: Próprio autor.

Para analisar o custo acumulado de energia durante o dia, a Figura 20 traz uma compilação de 8 casos, um para cada conjunto de carga para 5 conjuntos de regras diferentes. Nota-se que com apenas uma carga, como mostra a Figura 20(a) a diferença entre as curvas são sutis durante o dia, porém, ao analisar a Figura 20(h) é possível notar o comportamento mais dinâmico ao longo do dia e o impacto financeiro que cada conjunto de regras traz para o consumidor. É possível analisar uma redução no custo acumulado por volta do meio dia para diversos cenários devido a venda de energia e o conjunto de regras 5 possuindo o maior valor acumulado, sendo este similar a um consumidor sem um sistema de gerenciamento de energia para controlar os dispositivos inteligentes.


Figura 11 – Demanda Total para diferentes cargas e regras



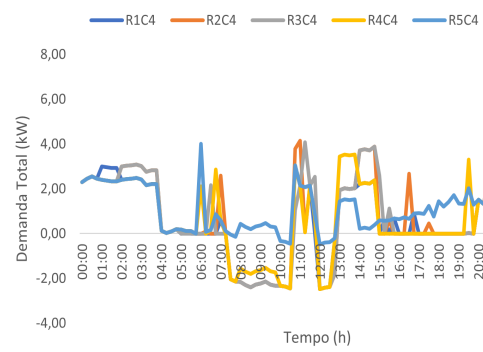
(a) 1 carga para diferentes regras




(b) 2 cargas para diferentes regras




(c) 3 cargas para diferentes regras



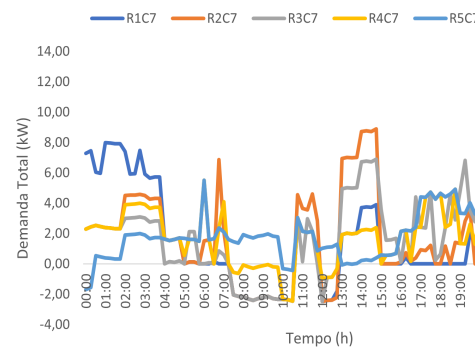
(d) 4 cargas para diferentes regras




(e) 5 cargas para diferentes regras



(f) 6 cargas para diferentes regras




(g) 7 cargas para diferentes regras



(h) 8 cargas para diferentes regras


Fonte: Próprio autor.

Figura 12 – Horários das 8 cargas ligadas para o conjunto de regra 1




Fonte: Próprio autor.

Figura 13 – Horários das 8 cargas ligadas para o conjunto de regra 2




Fonte: Próprio autor.

Figura 14 – Horários das 8 cargas ligadas para o conjunto de regra 3




Fonte: Próprio autor.

Figura 15 – Horários das 8 cargas ligadas para o conjunto de regra 4




Fonte: Próprio autor.

Figura 16 – Horários das 8 cargas ligadas para o conjunto de regra 5

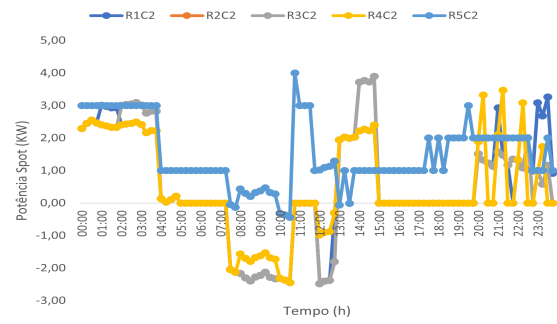


Fonte: Próprio autor.


Figura 17 – Potência spot comercializada




(a) Potência spot: 1 carga para diferentes regras




(b) Potência spot: 2 cargas para diferentes regras




(c) Potência spot: 3 cargas para diferentes regras




(d) Potência spot: 4 cargas para diferentes regras




(e) Potência spot: 5 cargas para diferentes regras



(f) Potência spot: 6 cargas para diferentes regras




(g) Potência spot: 7 cargas para diferentes regras




(h) Potência spot: 8 cargas para diferentes regras

Fonte: Próprio autor.


Figura 18 – Potência bilateral comercializada




(a) Potência bilateral: 1 carga para diferentes regras




(b) Potência bilateral: 2 cargas para diferentes regras




(c) Potência bilateral: 3 cargas para diferentes regras




(d) Potência bilateral: 4 cargas para diferentes regras




(e) Potência bilateral: 5 cargas para diferentes regras



(f) Potência bilateral: 6 cargas para diferentes regras




(g) Potência bilateral: 7 cargas para diferentes regras




(h) Potência bilateral: 8 cargas para diferentes regras

Fonte: Próprio autor.


Figura 19 – SOC da bateria




(a) SOC: 1 carga para diferentes regras




(b) SOC: 2 cargas para diferentes regras




(c) SOC: 3 cargas para diferentes regras




(d) SOC: 4 cargas para diferentes regras




(e) SOC: 5 cargas para diferentes regras



(f) SOC: 6 cargas para diferentes regras




(g) SOC: 7 cargas para diferentes regras




(h) SOC: 8 cargas para diferentes regras

Fonte: Próprio autor.


Figura 20 – Custo acumulado ao longo do dia




(a) Custo acumulado: 1 carga para diferentes regras




(b) Custo acumulado: 2 cargas para diferentes regras




(c) Custo acumulado: 3 cargas para diferentes regras




(d) Custo acumulado: 4 cargas para diferentes regras




(e) Custo acumulado: 5 cargas para diferentes regras



(f) Custo acumulado: 6 cargas para diferentes regras



(g) Custo acumulado: 7 cargas para diferentes regras



(h) Custo acumulado: 8 cargas para diferentes regras

Fonte: Próprio autor.

## 6 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho é mostrado o modelo e implementação de um sistema de gerenciamento residencial multiobjetivo. O sistema integra os recursos energéticos distribuídos (Energia solar fotovoltaica + Sistema de armazenamento de energia) e o mercado de dupla contratação (*Day-Ahead Pricing* + Tarifa fixa) através da linguagem Python. Primeiramente, foi realizada uma revisão sistemática no tema de resposta da demanda em cenários residenciais que utilizaram a otimização Programação Linear Inteira Mista (MILP) para reagendar o tempo de operação das cargas. Em seguida, foi descrito toda a formulação matemática para o desenvolvimento do Sistema de Gerenciamento de Energia Residencial e os parâmetros de avaliação.

A partir dos resultados obtidos conclui-se que o acréscimo de cargas e regras podem aumentar o tempo de simulação. Em alguns cenários simulados, o tempo de simulação aumentou substancialmente comparado como anterior, logo pode indicar uma exaustão computacional das condições de simulação e também uma possível troca para um outro modelo de otimização. Mas, por se tratar da consideração de cenários estocásticos, o tempo de simulação é factível, já que a sua presença aumenta os parâmetros de entrada que são enviados para o CPLEX. Em um cenário que envolva um computador mais robusto o tempo de solução será mais rápido, pois os recursos computacionais são utilizados pelo *solver* para processar a simulação.

Um dos pontos analisados quanto ao desempenho da RD é a avaliação do PAR e foi constatado que a utilização da RD por si só não reduz o *Peak-to-average Ratio*(PAR) e inclusive pode aumentar o PAR devido ao efeito rebote do deslocamento intensivo de cargas para uma região com menor preço como aconteceu com o conjunto de regras 1. A implementação de várias residências utilizando as mesmas condições que o conjunto simulado pode trazer prejuízos para a rede, para isso a implementação de um segundo nível de otimização por um agregador ou distribuidor de energia pode suavizar o impacto ao considerar a minimização do PAR, por exemplo.

Além disso, foram realizadas 40 simulações diferentes contendo conjuntos de restrições e cargas para testar os impactos no armazenamento da bateria, compra de energia no mercado bilateral, compra/venda no mercado *spot*, demanda total das cargas e custo total diário. Os resultados indicam que o acréscimo de carga e restrições gera uma dinâmica maior na alocação das cargas nos tempos ótimos para a função objetivo. Além disso, foi realizada uma comparação entre os cenários com ponderação de custo e sem custo na função objetivo e foi obtido uma redução de 77% no melhor cenário e a menor redução foi 35%. O resultado mostra

que a ponderação do custo no SGER performa de forma superior que a utilização apenas do conforto no que tange o custo de operação diário, já que o conforto prioriza o tempo de atuação próximo do desejado e naturalmente já pode indicar um maior custo financeiro, caso o tempo desejado seja em um horário com tarifa superior. Também foi observado que os componentes modelados com base nos parâmetros de mercado desempenharam um comportamento diferente quando a função objetivo visava apenas a minimização do desconforto. No cenário considerado apenas o conforto, a bateria teve baixa atuação, não houve compra no mercado bilateral, toda energia foi comprada no mercado spot e a venda de energia no mercado spot só aconteceu, pois a demanda líquida estava com valor negativo.

Por fim, conclui-se que os objetivos gerais e específicos foram alcançados por meio do desenvolvimento da modelagem e ao integrar dois formatos de contratação de energia, com programas de resposta da demanda, cenários estocásticos e recursos energéticos distribuídos.

## 6.1 Trabalhos Futuros

O sistema de gerenciamento de energia é uma ferramenta com uma gama muito grande de expansão, seja dentre a utilização das plataformas, *solvers*, programas de resposta da demanda, implementações práticas, otimizações, quantidades de residências, estocasticidade, cargas, sistemas de armazenamento, fontes de geração, parâmetros da função objetivos etc. Como evolução desse trabalho, sugere-se a aplicação dos seguintes pontos:

- Comparar o tempo de simulação determinístico com estocástico;
- Incluir veículos elétricos no formato veículo-casa e/ou veículo-rede;
- Incluir novas fontes de geração, como eólica e hidrogênio verde;
- Incluir novos parâmetros na função objetivo, como o PAR;
- Incluir uma nova camada de otimização gerenciada por um agregador de energia;
- Comparar diferentes espaços de tempo de operação, como a cada meia hora e a cada hora;
- Comparar com outros programas de resposta da demanda de preço e incentivo;
- Comparar com soluções de mercado mais próximas do contexto brasileiro;
- Comparar com outras linguagens, *solvers*, bibliotecas e algoritmos de otimização;
- Expandir na quantidade de residências consideradas na simulação;
- Embarcar a solução e comunicar a solução do *solver* por meio de uma comunicação com um servidor externo.

## REFERÊNCIAS

- ABDELWAHED, A. S.; ZEKRY, A.; AMER, G. M.; TAWFEEK, R. M. Implementation of a priority-based home energy management system. In: IEEE. **2021 International Mobile, Intelligent, and Ubiquitous Computing Conference (MIUCC)**. [S.l.], 2021. p. 84–89.
- AHMED, M.; MOHAMED, A.; HOMOD, R.; SHAREEF, H. Hybrid lsa-ann based home energy management scheduling controller for residential demand response strategy. **Energies**, MDPI, v. 9, n. 9, p. 716, 2016.
- AHMED, M. S.; MOHAMED, A.; KHATIB, T.; SHAREEF, H.; HOMOD, R. Z.; ALI, J. A. Real time optimal schedule controller for home energy management system using new binary backtracking search algorithm. **Energy and Buildings**, Elsevier, v. 138, p. 215–227, 2017. ISSN 0378-7788.
- ALFAVERH, F.; DENAI, M.; ALFAVERH, K. Demand-response based energy advisor for household energy management. In: IEEE. **2019 Third World Conference on Smart Trends in Systems Security and Sustainability (WorldS4)**. [S.l.], 2019. p. 153–157.
- ALFAVERH, F.; DENAI, M.; SUN, Y. User comfort-oriented home energy management system under demand response. In: IEEE. **2023 IEEE IAS Global Conference on Emerging Technologies (GlobConET)**. [S.l.], 2023. p. 1–7.
- ALFAVERH, K.; ALFAVERH, F.; SZAMEL, L. Plugged-in electric vehicle-assisted demand response strategy for residential energy management. **Energy Informatics**, Springer, v. 6, n. 1, p. 6, 2023.
- ALHASNAWI, B. N.; JASIM, B. H.; ESTEBAN, M. D.; GUERRERO, J. M. A novel smart energy management as a service over a cloud computing platform for nanogrid appliances. **Sustainability**, MDPI, v. 12, n. 22, p. 9686, 2020.
- ALILOU, M.; TOUSI, B.; SHAYEGHI, H. Home energy management in a residential smart micro grid under stochastic penetration of solar panels and electric vehicles. **Solar Energy**, Elsevier, v. 212, p. 6–18, 2020. ISSN 0038-092X.
- AMER, A.; SHABAN, K.; GAOUDA, A.; MASSOUD, A. Home energy management system embedded with a multi-objective demand response optimization model to benefit customers and operators. **Energies**, MDPI, v. 14, n. 2, p. 257, 2021.
- AYCİ, D.; ÖĞÜT, F.; ÖZEN, U.; İŞGÖR, B.; KÜFEOĞLU, S. Energy optimisation models for self-sufficiency of a typical turkish residential electricity customer of the future. **Energies**, MDPI, v. 14, n. 19, p. 6163, 2021.
- BESHEER, A.; AGAMY, M.; EMARA, H.; BAHGAT, A. Unified algorithm for demand-side appliance commitment. **Energies**, MDPI, v. 11, n. 12, p. 3337, 2018.
- BHAMIDI, L.; SIVASUBRAMANI, S. Optimal planning and operational strategy of a residential microgrid with demand side management. **IEEE Systems Journal**, IEEE, v. 14, n. 2, p. 2624–2632, 2020.
- BHAMIDI, L.; SIVASUBRAMANI, S. Optimal sizing of smart home renewable energy resources and battery under prosumer-based energy management. **IEEE Systems Journal**, IEEE, v. 15, n. 1, p. 105–113, 2020.

BRASIL. Ministério de Minas e Energia. Empresa de Pesquisa Energética. **Resposta da Demanda**: Conceitos, aspectos regulatórios e planejamento energético. Rio de Janeiro, 2019. Acesso em: 11 fev. 2025.

BUKSHSH, R.; JAVAID, N.; IQBAL, Z.; AHMED, U.; AHMAD, Z.; IQBAL, M. N. Appliances scheduling using hybrid scheme of genetic algorithm and elephant herd optimization for residential demand response. In: IEEE. **2018 32nd International Conference on Advanced Information Networking and Applications Workshops (WAINA)**. [S.l.], 2018. p. 210–217.

CHEN, X.; LI, J.; YANG, A.; ZHANG, Q. Artificial neural network-aided energy management scheme for unlocking demand response. In: IEEE. **2020 Chinese Control And Decision Conference (CCDC)**. [S.l.], 2020. p. 1901–1905.

DINH, H.; LEE, K.-H.; KIM, D. Supervised-learning-based hour-ahead demand response for a behavior-based home energy management system approximating milp optimization. **Applied Energy**, Elsevier, v. 321, p. 119382, 2022.

ELKAZAZ, M.; SUMNER, M.; NAGHIYEV, E.; PHOLBOON, S.; DAVIES, R.; THOMAS, D. A hierarchical two-stage energy management for a home microgrid using model predictive and real-time controllers. **Applied Energy**, Elsevier, v. 269, p. 115118, 2020. ISSN 0306-2619.

ENERGINET. **Nordpool Spot Market Data**. 2020. Disponível em: <https://www.energidataservice.dk/tso-electricity/nordpoolmarket#metadata-info>. Acesso em: 09 jan. 2025.

FAN, C.-H.; CHEN, H.; TSAI, C.-W. Sehas: a novel metaheuristic algorithm for home appliances scheduling in smart grid. In: IEEE. **2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)**. [S.l.], 2019. p. 786–791.

FAN, X. M.; LI, X. H.; DING, Y. M.; HE, J.; ZHAO, M. Demand response scheduling algorithm for smart residential communities considering heterogeneous energy consumption. **Energy and Buildings**, Elsevier, v. 279, 2023. ISSN 0378-7788.

GAZAFROUDI, A. S.; SOARES, J.; GHAZVINI, M. A. F.; PINTO, T.; VALE, Z.; CORCHADO, J. M. Stochastic interval-based optimal offering model for residential energy management systems by household owners. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 105, p. 201–219, 2019. ISSN 0142-0615.

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

GELLINGS, C. W. **The Smart Grid**: Enabling energy efficiency and demand response. [S.l.]: CRC Press, 2009.

HABIB, H. U. R.; WAQAR, A.; HUSSIEN, M.; JUNEJO, A.; JAHANGIRI, M.; IMRAN, R.; KIM, Y.-S.; KIM, J.-H. Analysis of microgrid's operation integrated to renewable energy and electric vehicles in view of multiple demand response programs. **IEEE Access**, IEEE, v. 10, p. 7598–7638, 2022.

HAFEEZ, G.; ALIMGEER, K.; WADUD, Z.; KHAN, I.; USMAN, M.; QAZI, A.; KHAN, F. An innovative optimization strategy for efficient energy management with day-ahead demand response signal and energy consumption forecasting in smart grid using artificial neural network. **IEEE Access**, IEEE, v. 8, p. 84415–84433, 2020.

- HAFEEZ, G.; WADUD, Z.; KHAN, I.; KHAN, I.; SHAFIQ, Z.; USMAN, M.; KHAN, M. Efficient energy management of iot-enabled smart homes under price-based demand response program in smart grid. **Sensors**, MDPI, v. 20, n. 11, p. 3155, 2020.
- HART, W. E.; WATSON, J.-P.; WOODRUFF, D. L. Pyomo: modeling and solving mathematical programs in python. **Mathematical Programming Computation**, Springer, v. 3, p. 219–260, 2011.
- HERATH, P.; VENAYAGAMOORTHY, G. Scalable residential demand response management. **IEEE Access**, IEEE, v. 9, p. 159133–159145, 2021.
- HUANG, Y.; ZHANG, J.; MO, Y.; LU, S.; MA, J. A hybrid optimization approach for residential energy management. **IEEE Access**, IEEE, v. 8, p. 225201–225209, 2020.
- HUSSAIN, B.; JAVAID, N.; HASAN, Q. U.; JAVAID, S.; KHAN, A.; MALIK, S. An inventive method for eco-efficient operation of home energy management systems. **Energies**, MDPI, v. 11, n. 11, p. 3091, 2018.
- HUSSAIN, B. *et al.* Demand side management for smart homes in pakistan. In: IEEE. **2016 International Conference on Emerging Technologies (ICET)**. [S.l.], 2016. p. 1–6.
- HUSSAIN, F.; HUANG, Q.; HUSSAIN, J.; MIRJAT, B. A.; MANZOOR, K.; AHMED, S. A. A smart home based on renewable energy with net-metering and energy storage technology. In: IEEE. **2023 13th International Conference on Power and Energy Systems (ICPES)**. [S.l.], 2023. p. 471–476.
- HUSSAIN, J.; HUANG, Q.; LI, J.; ZHANG, Z.; HUSSAIN, F.; AHMED, S. A.; MANZOOR, K. Microgrid and participant-centric residential demand response program and photovoltaic with battery-storage p2p energy trading for optimum energy management using mdlp and ppsd-admm. **Journal of Energy Storage**, Elsevier, v. 84, p. 110881, 2024.
- IBM Corporation. **Displaying problem statistics**. 2022. Disponível em: <https://www.ibm.com/docs/en/cofz/12.10.0?topic=problem-displaying-statistics>. Acesso em: 10 abr. 2025.
- IMRAN, A.; HAFEEZ, G.; KHAN, I.; USMAN, M.; SHAFIQ, Z.; QAZI, A.; KHALID, A.; THOBEN, K.-D. Heuristic-based programmable controller for efficient energy management under renewable energy sources and energy storage system in smart grid. **IEEE Access**, IEEE, v. 8, p. 139587–139608, 2020.
- IQBAL, M. M.; SAJJAD, M. I. A.; AMIN, S.; HAROON, S. S.; LIAQAT, R.; KHAN, M. F. N.; WASEEM, M.; SHAH, M. A. Optimal scheduling of residential home appliances by considering energy storage and stochastically modelled photovoltaics in a grid exchange environment using hybrid grey wolf genetic algorithm optimizer. **Applied Sciences**, MDPI, v. 9, n. 23, p. 5226, 2019.
- IQBAL, M. M.; ZIA, M. F.; BEDDIAR, K.; BENBOUZID, M. Optimal scheduling of grid transactive home demand responsive appliances using polar bear optimization algorithm. **IEEE Access**, IEEE, v. 8, p. 222285–222296, 2020. ISSN 2169-3536.
- JAVAID, N.; AHMED, F.; ULLAH, I.; ABID, S.; ABDUL, W.; ALAMRI, A.; ALMOGREN, A. Towards cost and comfort based hybrid optimization for residential load scheduling in a smart grid. **Energies**, MDPI, v. 10, n. 10, p. 1546, 2017.

- JOO, I.-Y.; CHOI, D.-H. Distributed optimization framework for energy management of multiple smart homes with distributed energy resources. **IEEE Access**, IEEE, v. 5, p. 15551–15560, 2017. ISSN 2169-3536.
- JORDEHI, A. R. Optimal scheduling of home appliances in home energy management systems using grey wolf optimisation (gwo) algorithm. In: IEEE. **2019 IEEE Milan PowerTech**. [S.l.], 2019. p. 1–6.
- JORDEHI, A. R. Enhanced leader particle swarm optimisation (elpso): a new algorithm for optimal scheduling of home appliances in demand response programs. **Artificial Intelligence Review**, Springer, v. 53, n. 3, p. 2043–2073, 2020. ISSN 0269-2821.
- KAKRAN, S.; CHANANA, S. Energy scheduling of residential appliances by a pigeon-inspired algorithm under a load shaping demand response program. **International journal on Electrical Engineering and Informatics**, Scopus, v. 11, n. 1, p. 18–34, 2019.
- KERSTING, W. H.; KERESTES, R. **Distribution System Modeling and Analysis with MATLAB® and WindMil®**. [S.l.]: CRC Press, 2022.
- KHALID, A.; JAVAID, N.; GUIZANI, M.; ALHUSSEIN, M.; AURANGZEB, K.; ILAHI, M. Towards dynamic coordination among home appliances using multi-objective energy optimization for demand side management in smart buildings. **IEEE Access**, IEEE, v. 6, p. 19509–19529, 2018.
- KHALID, M. U.; JAVAID, N. An optimal scheduling of smart home appliances using heuristic techniques with real-time coordination. In: IEEE. **2018 1st International Conference on Power, Energy and Smart Grid (ICPESG)**. [S.l.], 2018. p. 1–6.
- KHAN, Z. A.; KHALID, A.; JAVAID, N.; HASEEB, A.; SABA, T.; SHAFIQ, M. Exploiting nature-inspired-based artificial intelligence techniques for coordinated day-ahead scheduling to efficiently manage energy in smart grid. **IEEE Access**, IEEE, v. 7, p. 140102–140125, 2019. ISSN 2169-3536.
- KOK, J. K. **The powermatcher**: Smart coordination for the smart electricity grid. Phd Thesis (PhD Thesis) — Vrije Universiteit Amsterdam, 2013.
- KONG, X.; ZHANG, S.; SUN, B.; YANG, Q.; LI, S.; ZHU, S. Research on home energy management method for demand response based on chance-constrained programming. **Energies**, MDPI, v. 13, n. 11, p. 2790, 2020.
- LATIF, U.; JAVAID, N.; ZARIN, S. S.; NAZ, M.; JAMAL, A.; MATEEN, A. Cost optimization in home energy management system using genetic algorithm, bat algorithm and hybrid bat genetic algorithm. In: IEEE. **2018 IEEE 32nd international conference on advanced information networking and applications (AINA)**. [S.l.], 2018. p. 667–677.
- LI, H.; WAN, Z.; HE, H. A deep reinforcement learning based approach for home energy management system. In: IEEE. **2020 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)**. [S.l.], 2020. p. 1–5.
- LI, H.; ZENG, P.; ZANG, C.; YU, H.; LI, S. An integrative dr study for optimal home energy management based on approximate dynamic programming. **Sustainability**, MDPI, v. 9, n. 7, p. 1248, 2017.

- LI, S.; YANG, J.; SONG, W.; CHEN, A. A real-time electricity scheduling for residential home energy management. **IEEE Internet of Things Journal**, IEEE, v. 6, n. 2, p. 2602–2611, 2018.
- LI, W.; XU, X. A hybrid evolutionary and machine learning approach for smart building: Sustainable building energy management design. **Sustainable Energy Technologies and Assessments**, Elsevier, v. 65, p. 103709, 2024.
- LIANG, B.; LIU, W.; SUN, L.; HE, Z.; HOU, B. Economic mpc-based smart home scheduling with comprehensive load types, real-time tariffs, and intermittent ders. **IEEE Access**, IEEE, v. 8, p. 194373–194383, 2020.
- LIN, Y.-H.; HU, Y.-C. Residential consumer-centric demand-side management based on energy disaggregation-piloting constrained swarm intelligence: Towards edge computing. **Sensors**, MDPI, v. 18, n. 5, p. 1365, 2018.
- LIN, Y.-H.; TSAI, M.-S. An advanced home energy management system facilitated by nonintrusive load monitoring with automated multiobjective power scheduling. **IEEE Transactions on Smart Grid**, IEEE, v. 6, n. 4, p. 1839–1851, 2015.
- LUO, F.; RANZI, G.; WAN, C.; XU, Z.; DONG, Z. A multistage home energy management system with residential photovoltaic penetration. **IEEE Transactions on Industrial Informatics**, IEEE, v. 15, n. 1, p. 116–126, 2019.
- MAHMOOD, Z.; CHENG, B.; BUTT, N. A.; REHMAN, G. U.; ZUBAIR, M.; BADSHAH, A.; ASLAM, M. Efficient scheduling of home energy management controller (hemc) using heuristic optimization techniques. **Sustainability**, MDPI, v. 15, n. 2, 2023.
- MAHMOUDI, M.; AFSHARCHI, M.; KHODAYIFAR, S. Demand response management in smart homes using robust optimization. **Electric Power Components and Systems**, Taylor & Francis, v. 48, n. 8, p. 817–832, 2020. ISSN 1532-5008.
- MATEEN, A.; JAVAID, N.; AWAIS, M.; KHAN, N.; LATIF, U.; ULLAH, I. Bio-inspired optimization techniques for home energy management in smart grid. In: IEEE. **2018 32nd International Conference on Advanced Information Networking and Applications Workshops (WAINA)**. [S.l.], 2018. p. 250–257.
- MELO, L. S. Modelo de simulação computacional multidomínio para análise de redes elétricas inteligentes com aplicação em transações econômicas de energia. **Universidade Federal do Ceará–UFC**, 2022.
- MONYEI, C.; ADEWUMI, A. Integration of demand side and supply side energy management resources for optimal scheduling of demand response loads – south africa in focus. **Electric Power Systems Research**, Elsevier, v. 158, p. 92–104, 2018.
- MUNANKARMI, P.; MAGUIRE, J.; BALAMURUGAN, S. P.; BLONSKY, M.; ROBERTS, D.; JIN, X. Community-scale interaction of energy efficiency and demand flexibility in residential buildings. **Applied Energy**, Elsevier, v. 298, 2021. ISSN 0306-2619.
- NADEEM, Z.; JAVAID, N.; MALIK, A.; IQBAL, S. Scheduling appliances with ga, tlbo, fa, osr and their hybrids using chance constrained optimization for smart homes. **Energies**, MDPI, v. 11, n. 4, 2018.

NAKAGAWA, E.; SCANNAVINO, K.; FABBRI, S.; FERRARI, F. **Revisão Sistemática da Literatura em Engenharia de Software: Teoria e Prática**. [S.l.]: Elsevier Brasil, 2017. ISBN 9788535285970.

NAN, S.; ZHOU, M.; LI, G. Optimal residential community demand response scheduling in smart grid. **Applied Energy**, Elsevier, v. 210, p. 1280–1289, 2018. ISSN 0306-2619.

NAWAZ, A.; HAFEEZ, G.; KHAN, I.; USMAN, M.; JAN, K. U.; ULLAH, Z.; DIALLO, D. Demand-side management of residential service area under price-based demand response program in smart grid. In: IEEE. **2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)**. [S.l.], 2020. p. 1–6.

NEZHAD, A. E.; RAHIMNEJAD, A.; NARDELLI, P.; GADSDEN, S.; SAHOO, S.; GHANAVATI, F. A shrinking horizon model predictive controller for daily scheduling of home energy management systems. **IEEE Access**, IEEE, v. 10, p. 29716–29730, 2022.

NIE, X.; DAUD, W. M.; PU, J. A novel transactive integration system for solar renewable energy into smart homes and landscape design: A digital twin simulation case study. **Solar Energy**, Elsevier, v. 262, p. 111871, 2023.

NIZAMI, M.; HOSSAIN, M.; MAHMUD, K.; RAVISHANKAR, J. Energy cost optimization and der scheduling for unified energy management system of residential neighborhood. In: IEEE. **2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)**. [S.l.], 2018. p. 1–6.

OJAND, K.; DAGDOUGUI, H. Q-learning-based model predictive control for energy management in residential aggregator. **IEEE Transactions on Automation Science and Engineering**, IEEE, v. 19, n. 1, p. 70–81, 2022.

PANWAR, L. K.; REDDY, S. K.; VERMA, A.; PANIGRAHI, B. K. Dynamic incentive framework for demand response in distribution system using moving time horizon control. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 11, n. 17, p. 4338–4347, 2017. ISSN 1751-8687.

PARK, L.; JANG, Y.; BAE, H.; LEE, J.; PARK, C. Y.; CHO, S. Automated energy scheduling algorithms for residential demand response systems. **Energies**, MDPI, v. 10, n. 9, 2017. ISSN 1996-1073.

PARVIN, K.; HANNAN, M.; AL-SHETWI, A.; KER, P.; ROSLAN, M.; MAHLIA, T. Fuzzy based particle swarm optimization for modeling home appliances towards energy saving and cost reduction under demand response consideration. **IEEE Access**, IEEE, v. 8, p. 210784–210799, 2020.

PETRUCCI, A.; AYEVIDE, F.; BUONOMANO, A.; ATHIENITIS, A. Development of energy aggregators for virtual communities: The energy efficiency-flexibility nexus for demand response. **Renewable Energy**, Elsevier, v. 215, p. 118975, 2023.

PRIOLKAR, J.; SREERAJ, E. Optimal scheduling and demand response implementation for home energy management. **International journal of Electrical and Computer Engineering**, Scopus, v. 14, n. 2, p. 1352–1368, 2024.

RAHMAN, M. A.; RAHMAN, I.; MOHAMMAD, N. Demand side residential load management system for minimizing energy consumption cost and reducing peak demand in smart grid. In: IEEE. **2020 2nd International Conference on Advanced Information and Communication Technology (ICAICT)**. [S.l.], 2020. p. 376–381.

RAJASEKHAR, B.; PINDORIYA, N. M. Multi-stage scheduling for a smart home with solar pv and battery energy storage—a case study. In: IEEE. **2015 IEEE Innovative Smart Grid Technologies-Asia (ISGT ASIA)**. [S.l.], 2015. p. 1–6.

RAMALINGAM, S.; SHANMUGAM, P. Investigation on optimization algorithms for smart home energy management with different electricity pricing. **International journal of Electrical and Electronic Engineering and Telecommunications**, Scopus, v. 11, n. 6, p. 435–449, 2022.

RAMALINGAM, S. P.; SHANMUGAM, P. K. Scheduling smart home appliances using aco algorithm with different electricity tariff schemes. In: IEEE. **2021 Innovations in Power and Advanced Computing Technologies (i-PACT)**. [S.l.], 2021. p. 1–7.

RAMALINGAM, S. P.; SHANMUGAM, P. K. Optimal battery scheduling with and without renewable energy sources for efficient home energy management. In: IEEE. **2022 IEEE 19th India Council International Conference (INDICON)**. [S.l.], 2022. p. 1–8.

RASTEGAR, M.; FOTUHI-FIRUZABAD, M.; MOEINI-AGHTAI, M. Developing a two-level framework for residential energy management. **IEEE Transactions on Smart Grid**, IEEE, v. 9, n. 3, p. 1707–1717, 2018.

RATHOR, S. K.; SAXENA, D.; BALIVADA, R. An effective energy management system for smart residential buildings using binary particle swarm optimization. In: IEEE. **2020 3rd International Conference on Emerging Technologies in Computer Engineering: Machine Learning and Internet of Things (ICETCE)**. [S.l.], 2020. p. 63–68.

REGHUKUMAR, R.; SAMBHU, S.; PANDI, V. R. Multi-objective optimization for efficient home energy management system using differential evolution algorithm. In: IEEE. **2018 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)**. [S.l.], 2018. p. 1157–1162.

REHMAN, A.; WADUD, Z.; ELAVARASAN, R.; HAFEEZ, G.; KHAN, I.; SHAFIQ, Z.; ALHELOU, H. An optimal power usage scheduling in smart grid integrated with renewable energy sources for energy management. **IEEE Access**, IEEE, v. 9, p. 84619–84638, 2021.

REHMAN, A. U.; HAFEEZ, G.; ALBOGAMY, F.; WADUD, Z.; ALI, F.; KHAN, I.; RUKH, G.; KHAN, S. An efficient energy management in smart grid considering demand response program and renewable energy sources. **IEEE Access**, IEEE, v. 9, p. 148821–148844, 2021.

REKA, S. S.; RAMESH, V. Demand response scheme with electricity market prices for residential sector using stochastic dynamic optimization. In: IEEE. **2016 biennial international conference on power and energy systems: towards sustainable energy (PESTSE)**. [S.l.], 2016. p. 1–6.

REKA, S. S.; VENUGOPAL, P.; RAVI, V.; DRAGICEVIC, T. Privacy-based demand response modeling for residential consumers using machine learning with a cloud–fog-based smart grid environment. **Energies**, MDPI, v. 16, n. 4, 2023.

- ROY, T.; DAS, A.; NI, Z. Optimization in load scheduling of a residential community using dynamic pricing. In: IEEE. **2017 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)**. [S.l.], 2017. p. 1–5.
- SABOOR, A.; JAVAID, N.; IQBAL, Z.; ABBAS, Z.; KHAN, A. J.; RASHID, S.; AWAIS, M. Home energy management in smart grid using evolutionary algorithms. In: IEEE. **2018 IEEE 32nd international conference on Advanced Information Networking and Applications (AINA)**. [S.l.], 2018. p. 1070–1080.
- SADAT-MOHAMMADI, M.; NAZARI-HERIS, M.; NAZERFARD, E.; ABEDI, M.; ASADI, S.; JEBELLI, H. Intelligent approach for residential load scheduling. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 14, n. 21, p. 4738–4745, 2020. ISSN 1751-8687.
- SADIQ, F.; SAJJAD, I. A.; SADIQ, Z. Appliance scheduling in smart homes using jaya based optimization algorithm. In: IEEE. **2021 16th International Conference on Emerging Technologies (ICET)**. [S.l.], 2021. p. 1–6.
- SANGSWANG, A.; KONGHIRUN, M. Optimal strategies in home energy management system integrating solar power, energy storage, and vehicle-to-grid for grid support and energy efficiency. **IEEE Transactions on Industry Applications**, IEEE, v. 56, n. 5, p. 5716–5728, 2020.
- SANTOS, L. I. Modelo de mercado de eletricidade para sistemas de distribuição com resposta da demanda. **Universidade Federal do Ceará–UFC**, 2022.
- SHAFIQ, S.; ASIF, S.; FATIMA, I.; YOUSAF, K.; SAFAT, W.; JAVAID, N. An approach towards efficient scheduling of home energy management system using backtracking search optimization and tabu search. In: IEEE. **2018 32nd International Conference on Advanced Information Networking and Applications Workshops (WAINA)**. [S.l.], 2018. p. 226–231.
- SHEWALE, A.; MOKHADE, A.; LIPARE, A.; BOKDE, N. D. Efficient techniques for residential appliances scheduling in smart homes for energy management using multiple knapsack problem. **Arabian journal for Science and Engineering**, v. 49, n. 3, p. 3793–3813, 2024. ISSN 2193-567X.
- SINGH, B.; RAY, R.; BHADORIYA, J. S.; KUMAR, A.; GUPTA, A. R. Techno-economic feasibility analysis with energy storage and demand response program for the smart home energy management. **Electrical Engineering**, Springer, v. 106, n. 4, p. 5133–5152, 2024. ISSN 09487921.
- SLAMA, S. B.; MAHMOUD, M. A deep learning model for intelligent home energy management system using renewable energy. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 123, p. 106388, 2023.
- SPALTHOFF, C.; SARAJLIC, D.; KITTL, C.; DRAUZ, S.; KNEISKE, T.; REHTANZ, C.; BRAUN, M. Simbench: Open source time series of power load, storage and generation for the simulation of electrical distribution grids. In: VDE. **International ETG-Congress 2019; ETG Symposium**. [S.l.], 2019. p. 1–6.
- SULEMAN, A.; AMIN, M. A.; FATIMA, M.; ASAD, B.; MENGHWAR, M.; HASHMI, M. A. Smart scheduling of evs through intelligent home energy management using deep reinforcement

learning. In: IEEE. **2022 17th International Conference on Emerging Technologies (ICET)**. [S.l.], 2022. p. 18–24.

TAIK, S.; KISS, B. Demand side electric energy consumption optimization in a smart household using scheduling and model predictive temperature control. **Journal of Dynamic Systems, Measurement, and Control**, American Society of Mechanical Engineers, v. 143, n. 6, p. 061010, 2021.

TANTAWY, E.; AMER, G.; M.FAYEZ, H. Scheduling home appliances with integration of hybrid energy sources using intelligent algorithms. **Ain Shams Engineering journal**, Scopus, v. 13, n. 4, 2022.

TAVARES, T. M. Modelo de mercado varejista de eletricidade para sistemas de distribuição ativos. **Universidade Federal do Ceará–UFC**, 2019.

TOSTADO-VELIZ, M.; AREVALO, P.; KAMEL, S.; ZAWBAA, H. M.; JURADO, F. Home energy management system considering effective demand response strategies and uncertainties. **Energy Reports**, Elsevier, v. 8, p. 5256–5271, 2022. ISSN 2352-4847.

TOSTADO-VELIZ, M.; GHADIMI, A. A.; MIVEH, M. R.; MYYAS, R. N.; JURADO, F. A four-stage framework for optimal scheduling strategy of smart prosumers with vehicle-to-home capability under real time pricing based on interval optimization. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 17, n. 17, p. 3936–3950, 2023. ISSN 1751-8687.

TUTKUN, N.; BURGIO, A.; JASINSKI, M.; LEONOWICZ, Z.; JASINSKA, E. Intelligent scheduling of smart home appliances based on demand response considering the cost and peak-to-average ratio in residential homes. **Energies**, MDPI, v. 14, n. 24, p. 8510, 2021.

UNITED STATES. Department of Energy. **Benefits of Demand Response in Electricity Markets and Recommendations for Achieving Them**. Washington, D.C., 2006.

VERAS, J.; SILVA, I.; PINHEIRO, P.; RABÊLO, R.; VELOSO, A.; BORGES, F.; RODRIGUES, J. A multi-objective demand response optimization model for scheduling loads in a home energy management system. **Sensors**, MDPI, v. 18, n. 10, p. 3207, 2018.

WANG, X.; GUO, M.; WANG, S.; LV, R.; WANG, S.; LAN, L.; ZHAO, B. Demand response planning via home energy management system for residential aggregators in a virtual power plant. In: IEEE. **2023 8th Asia Conference on Power and Electrical Engineering (ACPEE)**. [S.l.], 2023. p. 1081–1085.

WANG, Z.; MUNAWAR, U.; PARANJAPE, R. Stochastic optimization for residential demand response with unit commitment and time of use. **IEEE Transactions on Industry Applications**, IEEE, v. 57, n. 2, p. 1767–1778, 2021.

WANG, Z.; PARANJAPE, R. Optimal residential demand response for multiple heterogeneous homes with real-time price prediction in a multiagent framework. **IEEE Transactions on Smart Grid**, IEEE, v. 8, n. 3, p. 1173–1184, 2017.

WASEEM, M.; KOUSER, F.; WAQAS, A. B.; IMRAN, N.; HAMEED, S.; FAHEEM, Z. B.; LIAQAT, R.; SHABBIR, U. Csoa-based residential energy management system in smart grid considering dgs for demand response. In: IEEE. **2021 International Conference on Digital Futures and Transformative Technologies (ICoDT2)**. [S.l.], 2021. p. 1–6.

WASEEM, M.; WAQAS, A. B.; ALI, Y.; KHAN, D.; FAHEEM, Z. B.; MANAN, A.; SHABBIR, U. Home energy management strategy for dr accomplishment considering pv uncertainties and battery energy storage system. In: IEEE. **2021 International Conference on Emerging Power Technologies (ICEPT)**. [S.l.], 2021. p. 1–5.

WU, Z.; ZHOU, S.; LI, J.; ZHANG, X.-P. Real-time scheduling of residential appliances via conditional risk-at-value. **IEEE Transactions on Smart Grid**, IEEE, v. 5, n. 3, p. 1282–1291, 2014.

XIONG, L.; TANG, Y.; LIU, C.; MAO, S.; MENG, K.; DONG, Z.; QIAN, F. Meta-reinforcement learning-based transferable scheduling strategy for energy management. **IEEE Transactions on Circuits and Systems I: Regular Papers**, IEEE, v. 70, n. 4, p. 1685–1695, 2023.

YAO, L.; DAMIRAN, Z.; LIM, W. H. Energy management optimization scheme for smart home considering different types of appliances. In: IEEE. **2017 IEEE international conference on environment and electrical engineering and 2017 IEEE industrial and commercial power systems Europe (EEEIC/I&CPS Europe)**. [S.l.], 2017. p. 1–6.

YAO, L.; SHEN, J.-Y.; LIM, W. H. Real-time energy management optimization for smart household. In: IEEE. **2016 IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData)**. [S.l.], 2016. p. 20–26.

YAO, L.; TEO, J. C. Optimization of power dispatch with load scheduling for domestic fuel cell-based combined heat and power system. **IEEE Access**, IEEE, v. 10, p. 5968–5979, 2022. ISSN 2169-3536.

YOUSSEF, H.; KAMEL, S.; HASSAN, M. H. Smart home energy management and power trading optimization using an enhanced manta ray foraging optimization. **Scientific Reports**, Nature Publishing Group UK London, v. 13, n. 1, p. 22163, 2023. ISSN 2045-2322.

YU, B.; SUN, F.; CHEN, C.; FU, G.; HU, L. Power demand response in the context of smart home application. **Energy**, Elsevier, v. 240, 2022. ISSN 0360-5442.

ZAMANLOO, S.; ABYANEH, H. A.; NAFISI, H.; AZIZI, M. Optimal two-level active and reactive energy management of residential appliances in smart homes. **Sustainable Cities and Society**, Elsevier, v. 71, p. 102972, 2021. ISSN 2210-6707.

ZHANG, D.; LI, S.; SUN, M.; O'NEILL, Z. An optimal and learning-based demand response and home energy management system. **IEEE transactions on smart grid**, IEEE, v. 7, n. 4, p. 1790–1801, 2016. ISSN 1949-3053.

ZHANG, D.; ZENG, P.; ZHANG, Y.; LI, S. An integrative study of home energy management for residential energy consumers. In: IEEE. **2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)**. [S.l.], 2015. p. 223–228.

ZHANG, Y.; ZENG, P.; LI, S.; ZANG, C.; LI, H. A novel multiobjective optimization algorithm for home energy management system in smart grid. **Mathematical Problems in Engineering**, Wiley Online Library, v. 2015, p. 807527, 2015.

ZHANG, Z.; WANG, J.; ZHONG, H.; MA, H. Optimal scheduling model for smart home energy management system based on the fusion algorithm of harmony search algorithm and particle swarm optimization algorithm. **Science and Technology for the Built Environment**, Taylor & Francis, v. 26, n. 1, SI, p. 42–51, 2020. ISSN 2374-4731.

ZHOU, J.; YANG, M.; ZHAN, Y.; XU, L. Digital twin application for reinforcement learning based optimal scheduling and reliability management enhancement of systems. **Solar Energy**, Elsevier, v. 252, p. 29–38, 2023.

ZINAMAN, O.; MILLER, M.; ADIL, A.; ARENT, D.; COCHRAN, J.; VORA, R.; AGGARWAL, S.; BIPATH, M.; LINVILL, C.; DAVID, A. *et al.* **Power systems of the future: a 21st century power partnership thought leadership report**. [S.l.], 2015.

## APÊNDICE A – STRINGS UTILIZADAS NAS PLATAFORMAS DE BUSCA

Tabela 11 – String do Web of Science

String
TS = (((Demand Response) OR DR) AND (home OR residential OR domestic) AND ((Energy Management) OR (Energy Efficiency)) AND (scheduling OR shift* OR adjustment OR optimization) NOT (Industrial OR Industrials OR Industry OR Industries OR factory OR manufacturing)) Timespan: 2014–2024. Índexes: SCI-EXPANDED, CPI-S, ESCI

Fonte: Próprio autor.

Tabela 12 – String do Scopus

String
TITLE-ABS-KEY (((demand AND response) OR dr) AND (home OR residential OR domestic) AND ((energy AND management) OR (energy AND efficiency)) AND (scheduling OR shift* OR adjustment OR optimization) AND NOT (industrial OR industrials OR industry OR industries OR factory OR manufacturing)) AND ( LIMIT-TO ( PUBYEAR,2014) OR LIMIT-TO ( PUBYEAR,2015) OR LIMIT-TO ( PUBYEAR,2016) OR LIMIT-TO ( PUBYEAR,2017) OR LIMIT-TO ( PUBYEAR,2018) OR LIMIT-TO ( PUBYEAR,2019) OR LIMIT-TO ( PUBYEAR,2020) OR LIMIT-TO ( PUBYEAR,2021) OR LIMIT-TO ( PUBYEAR,2022) OR LIMIT-TO ( PUBYEAR,2023) OR LIMIT-TO ( PUBYEAR,2024) ) AND ( LIMIT-TO ( DOCTYPE,"ar" ) )

Fonte: Próprio autor.

Tabela 13 – String do Engineering Village

String
2014–2024: (((((Demand Response) OR DR) AND (home OR residential OR domestic) AND ((Energy Management) OR (Energy Efficiency)) AND (Scheduling OR shift* OR adjustment OR optimization) NOT (Industrial OR Industrials OR Industry OR Industries OR factory OR manufacturing)) WN KY)

Fonte: Próprio autor.

Tabela 14 – String do IEEE Xplore

String
((Demand Response) OR DR) AND (home OR residential OR domestic) AND ((Energy Management) OR (Energy Efficiency)) AND (scheduling OR shift* OR adjustment OR optimization) Applied Filters:Conferences Journals & Magazines 2014–2024

Fonte: Próprio autor.

**APÊNDICE B – ARTIGOS SELECIONADOS PELA FASE 3 DA REVISÃO SISTEMÁTICA**

Tabela 15 – Artigos selecionados para a fase 3

Autores		
(Slama; Mahmoud, 2023)	(Taik; Kiss, 2021)	(Bhamidi; Sivasubramani, 2020a)
(Li <i>et al.</i> , 2020)	(Hussain <i>et al.</i> , 2016)	(Nan <i>et al.</i> , 2018)
(Tostado-Veliz <i>et al.</i> , 2023)	(Rahman <i>et al.</i> , 2020)	(Wang; Paranjape, 2017)
(Elkazaz <i>et al.</i> , 2020)	(Alfaverh <i>et al.</i> , 2019)	(Priolkar; Sreeraj, 2024)
(Li; Xu, 2024)	(Nawaz <i>et al.</i> , 2020)	(Zhang <i>et al.</i> , 2020)
(Huang <i>et al.</i> , 2020)	(Rastegar <i>et al.</i> , 2018)	(Iqbal <i>et al.</i> , 2020)
(Veras <i>et al.</i> , 2018)	(Petrucci <i>et al.</i> , 2023)	(Jordehi, 2019)
(Luo <i>et al.</i> , 2019)	(Zhou <i>et al.</i> , 2023)	(Iqbal <i>et al.</i> , 2019)
(Zhang <i>et al.</i> , 2015b)	(Joo; Choi, 2017)	(Bhamidi; Sivasubramani, 2020b)
(Alhasnawi <i>et al.</i> , 2020)	(Panwar <i>et al.</i> , 2017)	(Sangswang; Konghirun, 2020)
(Nie <i>et al.</i> , 2023)	(Liang <i>et al.</i> , 2020)	(Zamanloo <i>et al.</i> , 2021)
(Li <i>et al.</i> , 2018)	(Hafeez <i>et al.</i> , 2020b)	(Roy <i>et al.</i> , 2017)
(Nezhad <i>et al.</i> , 2022)	(Mahmood <i>et al.</i> , 2023)	(Yao; Teo, 2022)
(Hussain <i>et al.</i> , 2023)	(Shewale <i>et al.</i> , 2024)	(Alfaverh <i>et al.</i> , 2023b)
(Lin; Tsai, 2015)	(Nizami <i>et al.</i> , 2018)	(Yu <i>et al.</i> , 2022)
(Shafiq <i>et al.</i> , 2018)	(Yao <i>et al.</i> , 2017)	(Reka <i>et al.</i> , 2023)
(Rathor <i>et al.</i> , 2020)	(Aycı <i>et al.</i> , 2021)	(Ojand; Dagdougui, 2022)
(Rehman <i>et al.</i> , 2021b)	(Kakran; Chanana, 2019)	(Ahmed <i>et al.</i> , 2017)
(Hafeez <i>et al.</i> , 2020a)	(Jordehi, 2020)	(Yao <i>et al.</i> , 2016)
(Li <i>et al.</i> , 2017)	(Khan <i>et al.</i> , 2019)	(Wu <i>et al.</i> , 2014)
(Zhang <i>et al.</i> , 2015a)	(Parvin <i>et al.</i> , 2020)	(Kong <i>et al.</i> , 2020)
(Hussain <i>et al.</i> , 2018)	(Imran <i>et al.</i> , 2020)	(Lin; Hu, 2018)
(Zhang <i>et al.</i> , 2016)	(Alilou <i>et al.</i> , 2020)	(Herath; Venayagamoorthy, 2021)
(Rehman <i>et al.</i> , 2021a)	(Saboor <i>et al.</i> , 2018)	(Nadeem <i>et al.</i> , 2018)
(Khalid; Javaid, 2018)	(Waseem <i>et al.</i> , 2021b)	(Tantawy <i>et al.</i> , 2022)
(Habib <i>et al.</i> , 2022)	(Tostado-Veliz <i>et al.</i> , 2022)	(Ramalingam; Shanmugam, 2021)
(Sadiq <i>et al.</i> , 2021)	(Amer <i>et al.</i> , 2021)	(Fan <i>et al.</i> , 2019)
(Bukhsh <i>et al.</i> , 2018)	(Ahmed <i>et al.</i> , 2016)	(Youssef <i>et al.</i> , 2023)
(Chen <i>et al.</i> , 2020)	(Abdelwahed <i>et al.</i> , 2021)	(Suleman <i>et al.</i> , 2022)
(Park <i>et al.</i> , 2017)	(Monyei; Adewumi, 2018)	(Gazafroudi <i>et al.</i> , 2019)
(Mateen <i>et al.</i> , 2018)	(Sadat-Mohammadi <i>et al.</i> , 2020)	(Wang <i>et al.</i> , 2021)
(Munankarmi <i>et al.</i> , 2021)	(Tutkun <i>et al.</i> , 2021)	(Dinh <i>et al.</i> , 2022)
(Latif <i>et al.</i> , 2018)	(Ramalingam; Shanmugam, 2022)	(Singh <i>et al.</i> , 2024)
(Waseem <i>et al.</i> , 2021a)	(Xiong <i>et al.</i> , 2023)	(Javaid <i>et al.</i> , 2017)
(Mahmoudi <i>et al.</i> , 2020)	(Hussain <i>et al.</i> , 2024)	(Khalid <i>et al.</i> , 2018)
(Wang <i>et al.</i> , 2023)	(Reghukumar <i>et al.</i> , 2018)	(Besheer <i>et al.</i> , 2018)
(Fan <i>et al.</i> , 2023)	(Rajasekhar; Pindoriya, 2015)	(Alfaverh <i>et al.</i> , 2023a)
(Reka; Ramesh, 2016)	(Ramalingam; Shanmugam, 2022)	

Fonte: Próprio autor.

**APÊNDICE C – BIBLIOTECAS INSTALADAS NO AMBIENTE DO PYTHON**

Tabela 16 – Bibliotecas e versões instaladas no ambiente

Biblioteca	Versão	Biblioteca	Versão	Biblioteca	Versão
asttokens	2.4.1	libbrotlidec	1.0.9	pyomo	5.7.3
blas	1.0	libbrotlienc	1.0.9	pyparsing	3.0.9
blosc	1.21.3	libclang	14.0.6	pyqt	5.15.10
bottleneck	1.3.7	libclang13	14.0.6	pyqt5-sip	12.13.0
brotli	1.0.9	libdeflate	1.17	pysocks	1.7.1
brotli-bin	1.0.9	libffi	3.4.4	pytables	3.8.0
brotli-python	1.0.9	libpng	1.6.39	python	3.10.14
bzip2	1.0.8	libpq	12.17	python-dateutil	2.9.0post0
c-blosc2	2.12.0	libsodium	1.0.18	python_abi	3.10
ca-certificates	2024.3.11	libtiff	4.5.1	pytz	2024.1
certifi	2024.6.2	libwebp-base	1.3.2	pyutilib	6.0.0
charset-normalizer	2.0.4	lz4-c	1.9.4	pywin32	306
click	8.1.7	lzo	2.10	pyzmq	26.0.3
colorama	0.4.6	matplotlib	3.6.2	qt-main	5.15.2
comm	0.2.2	matplotlib-base	3.6.2	requests	2.32.3
contourpy	1.2.0	matplotlib-inline	0.1.7	setuptools	69.5.1
cycler	0.11.0	mk1	2021.4.0	sip	6.7.12
debugpy	1.8.1	mk1-service	2.4.0	six	1.16.0
decorator	5.1.1	mk1_fft	1.3.1	sqlite	3.45.3
et_xmlfile	1.1.0	mk1_random	1.2.2	stack_data	0.6.2
exceptiongroup	1.2.0	nest-asyncio	1.6.0	tk	8.6.14
executing	2.0.1	networkx	2.8.8	tomli	2.0.1
fonttools	4.51.0	nose	1.3.7	tornado	6.3.3
freetype	2.12.1	numexpr	2.8.4	traitlets	5.14.3
hdf5	1.12.1	numpy	1.23.4	typing_extensions	4.11.0
icc_rt	2022.1.0	numpy-base	1.23.4	tzdata	2024a
icu	73.1	openjpeg	2.4.0	ucrt	10.0.22621.0
idna	3.7	openpyxl	3.0.10	unicodedata2	15.1.0
importlib-metadata	7.1.0	openssl	3.3.0	urllib3	2.2.1
importlib_metadata	7.1.0	packaging	23.2	vc	14.2
intel-openmp	2021.4.0	pandas	1.5.2	vc14_runtime	14.38.33130
ipykernel	6.29.3	parso	0.8.4	vs2015_runtime	14.38.33130
ipython	8.24.0	pickleshare	0.7.5	wcwidth	0.2.13
jedi	0.19.1	pillow	10.3.0	wheel	0.43.0
jpeg	9e	pip	24.0	win_inet_pton	1.1.0
jupyter_client	8.6.1	platformdirs	4.2.2	xz	5.4.6
jupyter_core	5.7.2	ply	3.11	zeromq	4.3.5
kiwisolver	1.4.4	prompt-toolkit	3.0.42	zipp	3.17.0
krb5	1.20.1	psutil	5.9.8	zlib	1.2.13
lcms2	2.12	pure_eval	0.2.2	zlib-ng	2.0.7
lerc	3.0	py-cpuinfo	9.0.0	zstd	1.5.5
libbrotlicommon	1.0.9	pygments	2.18.0		

## APÊNDICE D – ESTRUTURAÇÃO DO CÓDIGO

O primeiro refere-se ao arquivo *Load\_data.py*, nele os dados de geração, consumo e preço são retirados de arquivos no formato ".csv" e em seguida, os dados são tratados para estarem aptos a serem utilizados em outros trechos do código.

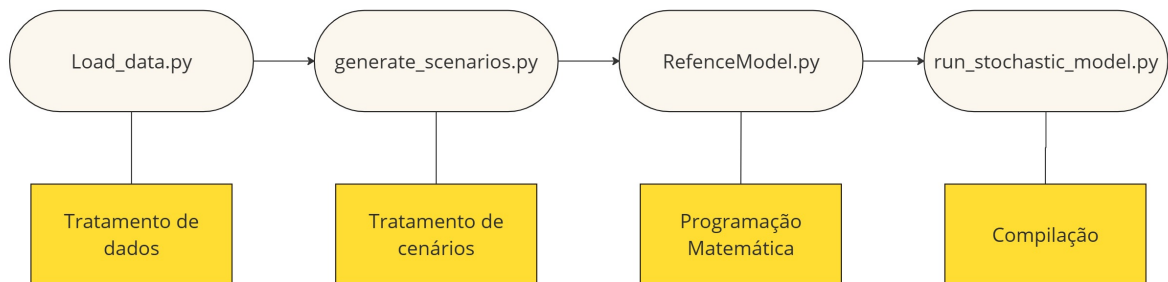
O segundo é o *generate\_scenarios.py*, em que neste arquivo, os dados de geração fotovoltaica são parametrizados para uma potência de 1 kW e de consumo são parametrizados para uma potência de 4 kW. Além disso, no *generate\_scenarios*, os cenários estocásticos são reduzidos e combinados e além de gerar um arquivo auxiliar no formato ".dat" que contempla a estruturação da ramificação de dois estágios da estocasticidade.

O terceiro é o *ReferenceModel.py*, neste arquivo é descrita toda a linguagem matemática do mercado, bateria, resposta da demanda e cargas, conforme está na Seção 4.3.

O quarto é o *run\_stochastic\_model*, aqui os arquivos são incluídos na função do *solver CPLEX* para computar a solução ótima para o caso gerado. Ademais, os gráficos dispostos no Capítulo 5 foram extraídos desse arquivo.

Na Figura 21 resume o fluxograma dos 4 arquivos, além de caracterizar de forma breve cada um.

Figura 21 – Arquivos com extensão “.py” utilizados no Python



Fonte: Próprio autor.