



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
MESTRADO EM ENGENHARIA ELÉTRICA

JOÃO HUGO CADEIRA BRANDÃO

**SIMULAÇÃO DE SISTEMAS DE ARMAZENAMENTO DE ENERGIA ASSOCIADOS  
À MICROGERAÇÃO ATRAVÉS DE ALGORITMOS EVOLUTIVOS EM REDES DE  
MÉDIA TENSÃO**

MOSSORÓ - RN

2025

JOÃO HUGO CADEIRA BRANDÃO

**SIMULAÇÃO DE SISTEMAS DE ARMAZENAMENTO DE ENERGIA ASSOCIADOS  
À MICROGERAÇÃO ATRAVÉS DE ALGORITMOS EVOLUTIVOS EM REDES DE  
MÉDIA TENSÃO**

Dissertação de mestrado acadêmico apresentada ao programa de Mestrado em Engenharia Elétrica da Pró-Reitoria de Pesquisa e Pós-graduação da Universidade Federal Rural do Semi-Árido, como requisito à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Sistemas Elétricos.

Orientador: Prof. Dr. Ednardo Pereira da Rocha

MOSSORÓ - RN

2025

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

C817s Cadeira Brandão, João Hugo .  
Simulação de sistemas de armazenamento de energia associados à microgeração através de algoritmos evolutivos em redes de média tensão / João Hugo Cadeira Brandão. - 2025.  
114 f. : il.

Orientador: Ednardo Pereira da Rocha.  
Dissertação (Mestrado) - Universidade Federal Rural do Semi-árido, Programa de Pós-graduação em Engenharia Elétrica, 2025.

1. Inteligência artificial. 2. Algoritmo genético. 3. Evolução Diferencial. 4. BESS (Battery Energy Storage System). 5. Geração distribuída. I. Pereira da Rocha, Ednardo , orient. II. Título.

Ficha catalográfica elaborada por sistema gerador automático em conformidade com AACR2 e os dados fornecidos pelo autor(a).  
Biblioteca Campus Mossoró / Setor de Informação e Referência  
Bibliotecária: Keina Cristina Santos Sousa e Silva  
CRB: 15/120

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

JOÃO HUGO CADEIRA BRANDÃO

**SIMULAÇÃO DE SISTEMAS DE ARMAZENAMENTO DE ENERGIA ASSOCIADOS  
À MICROGERAÇÃO ATRAVÉS DE ALGORITMOS EVOLUTIVOS EM REDES DE  
MÉDIA TENSÃO**

Dissertação de mestrado acadêmico apresentada ao programa de Mestrado em Engenharia Elétrica da Pró-Reitoria de Pesquisa e Pós-graduação da Universidade Federal Rural do Semi-Árido, como requisito à obtenção do título de mestre em Engenharia Elétrica. Área de Concentração: Sistemas Elétricos.

Defendida em: 21 de fevereiro de 2025

**BANCA EXAMINADORA**

---

Prof. Dr. Ednardo Pereira da Rocha (Orientador)  
Universidade Federal Rural do Semi-árido (UFERSA)

---

Prof. Dr. Rogerio Diogne de Souza e Silva  
Membro Externo

---

Prof. Dr. Adriano Aron Freiras de Moura  
Universidade Federal Rural do Semi-árido (UFERSA)

## RESUMO

Este estudo apresenta uma pesquisa aplicada que visa desenvolver uma ferramenta de otimização para simular o desempenho de um sistema de armazenamento de energia em baterias (BESS) associado à geração distribuída. No caso do presente trabalho, o estudo de caso será a Universidade Federal Rural do Semi-Árido (UFERSA). A simulação tem como objetivo analisar o comportamento do sistema em termos de parâmetros elétricos e avaliar a economia obtida relacionada aos custos com energia e desgaste da bateria. A metodologia utiliza inteligência artificial para determinar o ponto ótimo do sistema, aplicando dois algoritmos evolutivos: o algoritmo genético e a evolução diferencial. Ambos os métodos são avaliados quanto à sua eficácia, considerando parâmetros como tempo de simulação e critérios de parada. Além disso, o trabalho realiza uma comparação entre os dois métodos, destacando suas vantagens e limitações. Os resultados demonstram que a ferramenta desenvolvida atinge seu objetivo principal, fornecendo simulações completas para todos os meses do ano e uma análise simplificada do retorno financeiro, contribuindo para a avaliação técnica e econômica de sistemas de armazenamento de energia em cenários reais.

**Palavras-chave:** Inteligência artificial. Algoritmo genético. Evolução Diferencial. BESS (Battery Energy Storage System). Geração distribuída.

## ABSTRACT

This study presents applied research aimed at developing an optimization tool to simulate the performance of a Battery Energy Storage System (BESS) associated with distributed generation. In the case of this work, the case study will be the Federal Rural University of the Semi-Arid Region (UFERSA). The simulation aims to analyze the system's behavior in terms of electrical parameters and evaluate the cost savings related to energy expenses and battery degradation. The methodology employs artificial intelligence to determine the system's optimal point, applying two evolutionary algorithms: the genetic algorithm and differential evolution. Both methods are assessed for their effectiveness, considering parameters such as simulation time and stopping criteria. Additionally, the study conducts a comparison between the two methods, highlighting their advantages and limitations. The results demonstrate that the developed tool achieves its main objective, providing comprehensive simulations for all months of the year and a simplified analysis of financial returns, contributing to the technical and economic evaluation of energy storage systems in real-world scenarios.

**Keywords:** Artificial Intelligence. Genetic Algorithm. Differential Evolution. BESS (Battery Energy Storage System). Distributed Generation.

## LISTA DE FIGURAS

Figura 1 – Tecnologias de Armazenamento de Energia . . . . .	18
Figura 2 – Esquema de uma usina hidrelétrica reversível . . . . .	18
Figura 3 – Esquema de uma usina a ar comprimido . . . . .	19
Figura 4 – Esquema de um volante armazenador de energia . . . . .	20
Figura 5 – Esquema de um SMES . . . . .	21
Figura 6 – Esquema de construção dos Supercapacitores . . . . .	23
Figura 7 – Classificação dos serviços com base na natureza, duração e frequência . . . . .	25
Figura 8 – Faixas de potência e tempo de descarga para cada tecnologia de armazenamento de energia (ESS) . . . . .	26
Figura 9 – Esquema básico dos componentes do BESS . . . . .	27
Figura 10 – Perfil de tensão em função da profundidade de descarga. . . . .	27
Figura 11 – Balanceamento de uma célula de bateria. . . . .	28
Figura 12 – Inversão de 48 V CC para 220 V CA.. . . . .	29
Figura 13 – Evolução da informação genética. . . . .	31
Figura 14 – Cruzamento com único ponto. . . . .	33
Figura 15 – Fluxograma algoritmo Genético. . . . .	34
Figura 16 – Fluxograma Evolução Diferencial. . . . .	35
Figura 17 – Fluxograma da metodologia . . . . .	40
Figura 18 – Fluxograma da ferramenta de otimização . . . . .	46
Figura 19 – Efeito do algoritmo genético em um dia típico de janeiro . . . . .	48
Figura 20 – Efeito do evolução diferencial em um dia típico de janeiro . . . . .	49
Figura 21 – Comportamento do erro do algoritmo genético num dia típico de janeiro . . . . .	50
Figura 22 – Comportamento do erro do evolução diferencial num dia típico de janeiro . . . . .	51
Figura 23 – Consistência do algoritmo genético para o mês de janeiro . . . . .	52
Figura 24 – Consistência do evolução diferencial para o mês de janeiro . . . . .	53
Figura 25 – Desvio padrão nas compilações dos métodos utilizados . . . . .	53
Figura 26 – Similaridade de convergência de ambos os métodos . . . . .	54
Figura 27 – Perfil de consumo de um dia típico do mês de janeiro . . . . .	63
Figura 28 – Perfil de consumo de um dia típico do mês de fevereiro . . . . .	63
Figura 29 – Perfil de consumo de um dia típico do mês de março . . . . .	64
Figura 30 – Perfil de consumo de um dia típico do mês de abril . . . . .	64

Figura 31 – Perfil de consumo de um dia típico do mês de maio . . . . .	65
Figura 32 – Perfil de consumo de um dia típico do mês de junho . . . . .	65
Figura 33 – Perfil de consumo de um dia típico do mês de julho . . . . .	66
Figura 34 – Perfil de consumo de um dia típico do mês de agosto . . . . .	66
Figura 35 – Perfil de consumo de um dia típico do mês de setembro . . . . .	67
Figura 36 – Perfil de consumo de um dia típico do mês de outubro . . . . .	67
Figura 37 – Perfil de consumo de um dia típico do mês de novembro . . . . .	68
Figura 38 – Perfil de consumo de um dia típico do mês de dezembro . . . . .	68
Figura 39 – Perfil de geração em janeiro . . . . .	75
Figura 40 – Perfil de geração em fevereiro . . . . .	75
Figura 41 – Perfil de geração em março . . . . .	76
Figura 42 – Perfil de geração em abril . . . . .	76
Figura 43 – Perfil de geração em maio . . . . .	76
Figura 44 – Perfil de geração em junho . . . . .	77
Figura 45 – Perfil de geração em julho . . . . .	77
Figura 46 – Perfil de geração em agosto . . . . .	77
Figura 47 – Perfil de geração em setembro . . . . .	78
Figura 48 – Perfil de geração em outubro . . . . .	78
Figura 49 – Perfil de geração em novembro . . . . .	78
Figura 50 – Perfil de geração em dezembro . . . . .	79
Figura 51 – Efeito do algoritmo genético em um dia típico de fevereiro . . . . .	80
Figura 52 – Efeito do algoritmo genético em um dia típico de março . . . . .	80
Figura 53 – Efeito do algoritmo genético em um dia típico de abril . . . . .	81
Figura 54 – Efeito do algoritmo genético em um dia típico de maio . . . . .	81
Figura 55 – Efeito do algoritmo genético em um dia típico de junho . . . . .	82
Figura 56 – Efeito do algoritmo genético em um dia típico de julho . . . . .	82
Figura 57 – Efeito do algoritmo genético em um dia típico de agosto . . . . .	83
Figura 58 – Efeito do algoritmo genético em um dia típico de setembro . . . . .	83
Figura 59 – Efeito do algoritmo genético em um dia típico de outubro . . . . .	84
Figura 60 – Efeito do algoritmo genético em um dia típico de novembro . . . . .	84
Figura 61 – Efeito do algoritmo genético em um dia típico de dezembro . . . . .	85
Figura 62 – Efeito do evolução diferencial em um dia típico de fevereiro . . . . .	85

Figura 63 – Efeito do evolução diferencial em um dia tipico de março . . . . .	86
Figura 64 – Efeito do evolução diferencial em um dia tipico de abril . . . . .	86
Figura 65 – Efeito do evolução diferencial em um dia tipico de maio . . . . .	87
Figura 66 – Efeito do evolução diferencial em um dia tipico de junho . . . . .	87
Figura 67 – Efeito do evolução diferencial em um dia tipico de julho . . . . .	88
Figura 68 – Efeito do evolução diferencial em um dia tipico de agosto . . . . .	88
Figura 69 – Efeito do evolução diferencial em um dia tipico de setembro . . . . .	89
Figura 70 – Efeito do evolução diferencial em um dia tipico de outubro . . . . .	89
Figura 71 – Efeito do evolução diferencial em um dia tipico de novembro . . . . .	90
Figura 72 – Efeito do evolução diferencial em um dia tipico de dezembro . . . . .	90
Figura 73 – Comportamento do erro do algoritimo genético num dia típico de fevereiro .	91
Figura 74 – Comportamento do erro do algoritimo genético num dia típico de março . .	91
Figura 75 – Comportamento do erro do algoritimo genético num dia típico de abril . . .	92
Figura 76 – Comportamento do erro do algoritimo genético num dia típico de maio . . .	92
Figura 77 – Comportamento do erro do algoritimo genético num dia típico de junho . .	93
Figura 78 – Comportamento do erro do algoritimo genético num dia típico de julho . . .	93
Figura 79 – Comportamento do erro do algoritimo genético num dia típico de agosto . .	94
Figura 80 – Comportamento do erro do algoritimo genético num dia típico de setembro .	94
Figura 81 – Comportamento do erro do algoritimo genético num dia típico de outubro .	95
Figura 82 – Comportamento do erro do algoritimo genético num dia típico de novembro	95
Figura 83 – Comportamento do erro do algoritimo genético num dia típico de dezembro	96
Figura 84 – Comportamento do erro do evolução diferencial num dia típico de fevereiro	96
Figura 85 – Comportamento do erro do evolução diferencial num dia típico de março . .	97
Figura 86 – Comportamento do erro do evolução diferencial num dia típico de abril . . .	97
Figura 87 – Comportamento do erro do evolução diferencial num dia típico de maio . . .	98
Figura 88 – Comportamento do erro do evolução diferencial num dia típico de junho . . .	98
Figura 89 – Comportamento do erro do evolução diferencial num dia típico de julho . . .	99
Figura 90 – Comportamento do erro do evolução diferencial num dia típico de agosto . . .	99
Figura 91 – Comportamento do erro do evolução diferencial num dia típico de setembro	100
Figura 92 – Comportamento do erro do evolução diferencial num dia típico de outubro .	100
Figura 93 – Comportamento do erro do evolução diferencial num dia típico de novembro	101
Figura 94 – Comportamento do erro do evolução diferencial num dia típico de dezembro	101

Figura 95 – Consistência do algoritmo genético para o mês de fevereiro . . . . .	102
Figura 96 – Consistência do algoritmo genético para o mês de março . . . . .	102
Figura 97 – Consistência do algoritmo genético para o mês de abril . . . . .	103
Figura 98 – Consistência do algoritmo genético para o mês de maio . . . . .	103
Figura 99 – Consistência do algoritmo genético para o mês de junho . . . . .	104
Figura 100 – Consistência do algoritmo genético para o mês de julho . . . . .	104
Figura 101 – Consistência do algoritmo genético para o mês de agosto . . . . .	105
Figura 102 – Consistência do algoritmo genético para o mês de setembro . . . . .	105
Figura 103 – Consistência do algoritmo genético para o mês de outubro . . . . .	106
Figura 104 – Consistência do algoritmo genético para o mês de novembro . . . . .	106
Figura 105 – Consistência do algoritmo genético para o mês de dezembro . . . . .	107
Figura 106 – Consistência do evolução diferencial para o mês de fevereiro . . . . .	107
Figura 107 – Consistência do evolução diferencial para o mês de março . . . . .	108
Figura 108 – Consistência do evolução diferencial para o mês de março . . . . .	108
Figura 109 – Consistência do evolução diferencial para o mês de abril . . . . .	109
Figura 110 – Consistência do evolução diferencial para o mês de maio . . . . .	109
Figura 111 – Consistência do evolução diferencial para o mês de junho . . . . .	110
Figura 112 – Consistência do evolução diferencial para o mês de julho . . . . .	110
Figura 113 – Consistência do evolução diferencial para o mês de agosto . . . . .	111
Figura 114 – Consistência do evolução diferencial para o mês de setembro . . . . .	111
Figura 115 – Consistência do evolução diferencial para o mês de outubro . . . . .	112
Figura 116 – Consistência do evolução diferencial para o mês de novembro . . . . .	112
Figura 117 – Consistência do evolução diferencial para o mês de dezembro . . . . .	113

## LISTA DE TABELAS

Tabela 1 – Termos técnicos no contexto dos sistemas de armazenamento de energia . . .	37
Tabela 2 – Parâmetros relativos à natureza, duração e frequência de um serviço . . . . .	38
Tabela 3 – Comparação de Custos Mensais entre os Métodos ED e AG . . . . .	55
Tabela 4 – Tempo de simulação das 10 compilações . . . . .	56

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	13
<b>1.1</b>	<b>Proposta da Pesquisa</b>	15
1.1.1	Proposta da Ferramenta de Otimização de energia	15
<b>1.2</b>	<b>Objetivos</b>	15
<b>1.3</b>	<b>Resumo dos Capítulos</b>	15
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	17
<b>2.1</b>	<b>Sistemas de Armazenamento de Energia: Tecnologias em geral</b>	17
2.1.1	Tecnologias para armazenar energia	17
2.1.1.1	Usina Hidrelétrica Reversível	17
2.1.1.2	Armazenamento de Energia em Ar Comprimido	19
2.1.1.3	Volante de Inércia (FLYWHEEL)	20
2.1.1.4	Bobinas Supercondutoras (SMES)	21
2.1.1.5	Super Capacitores	22
2.1.1.6	Sistemas Eletroquímicos (Baterias)	22
2.1.1.7	Sistemas Térmicos	24
2.1.2	Armazenamento de Energia para uma Determinada Aplicação	24
2.1.3	Componentes do BESS	26
2.1.3.1	Bateria	26
2.1.3.2	BMS	28
2.1.3.3	PCS	29
2.1.3.4	EMS	30
<b>2.2</b>	<b>Inteligencia Artificial e métodos heurísticos</b>	30
2.2.1	Algoritmo Genético (AG)	32
2.2.2	Evolução Diferencial (ED)	33
<b>2.3</b>	<b>arbitragem de Tarifas</b>	35
<b>2.4</b>	<b>Geração de usina solar - Método da insolação</b>	36
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	39
<b>3.1</b>	<b>Ferramenta de Otimização</b>	39
3.1.1	Origem dos dados de entrada	39
3.1.2	Perfil de consumo	40

3.1.3	Preço dos postos tarifários . . . . .	40
3.1.4	Capacidade da bateria . . . . .	41
3.1.5	Perfil de geração solar . . . . .	41
3.1.6	Potência nominal da bateria . . . . .	42
3.1.7	Número de ciclos . . . . .	43
3.1.8	Custo da bateria . . . . .	43
<b>3.2</b>	<b>Função de Aptidão . . . . .</b>	<b>43</b>
<b>3.3</b>	<b>Implementação . . . . .</b>	<b>45</b>
3.3.1	Algoritmo da ferramenta de otimização . . . . .	45
<b>4</b>	<b>ANÁLISE DOS RESULTADOS . . . . .</b>	<b>48</b>
<b>4.1</b>	<b>Comportamento dos parâmetros elétricos . . . . .</b>	<b>48</b>
<b>4.2</b>	<b>Comportamento da convergência através do erro . . . . .</b>	<b>50</b>
<b>4.3</b>	<b>Análise da consistência do resultado . . . . .</b>	<b>51</b>
<b>4.4</b>	<b>Análise do resultado financeiro . . . . .</b>	<b>54</b>
<b>4.5</b>	<b>Tempo de simulação . . . . .</b>	<b>54</b>
<b>5</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS . . . . .</b>	<b>57</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>59</b>
	<b>ANEXOS . . . . .</b>	<b>62</b>
	<b>ANEXO A – Perfil de consumo . . . . .</b>	<b>63</b>
	<b>ANEXO B – DATASHEET: EMSJ 340P . . . . .</b>	<b>69</b>
	<b>ANEXO C – Perfil de geração solar . . . . .</b>	<b>75</b>
	<b>ANEXO D – Comportamento dos parâmetros elétricos . . . . .</b>	<b>80</b>
	<b>ANEXO E – Convergência do erro . . . . .</b>	<b>91</b>
	<b>ANEXO F – Consistência do resultado ao longo de 10 compilações . . . . .</b>	<b>102</b>

## 1 INTRODUÇÃO

No âmbito da energia elétrica no mundo, os estudos para novas tecnologias possuem um foco na melhor utilização da energia elétrica gerada, buscando a preservação do meio ambiente e redução de custos para o consumidor, desde a preservação de equipamentos e o uso correto de eletricidade. Tendo isso em vista, a presente pesquisa busca estudar a aplicabilidade de Sistemas de Armazenamento de Energia (SAE), aliado ao uso de energia solar e inteligência artificial (BUENO; BRANDAO, 2016).

O surgimento dos sistemas fotovoltaicos possibilitou que a energia elétrica fosse produzida de forma descentralizada, onde o consumidor tem mais controle diante das usinas geradoras de energia. Nesse contexto, surge a necessidade de aplicar os SAE's para trazer mais qualidade e segurança para a energia produzida de forma individual, tendo em vista a instabilidade na potencia extraída (BUENO; BRANDAO, 2016).

Dentre as principais vantagens da utilização dos SAE's, destaca-se a sustentabilidade, uma vez que contribuem para a redução do congestionamento na rede elétrica. Cada novo sistema fotovoltaico instalado eleva o nível de potência na rede, gerando sobrecargas e acelerando o desgaste de cabos e equipamentos (COSTA; BORTONI, 2016). Os SAE's também podem ser utilizados para fornecer potência reativa, o que corrige o fator de potência, beneficiando tanto o consumidor quanto a concessionária (DAZA, 2020). Além disso, os SAE's podem suprir demandas imediatas sempre que necessário, cobrir perdas e garantir a operação do sistema (PEREIRA, 2020), bem como realizar a arbitragem de energia entre a geração e o consumo final dentro de uma região específica em um intervalo de tempo determinado (SOUZA, 2020). Durante interrupções no fornecimento de energia, as baterias podem descarregar para suprir a falta de eletricidade (AKHIL *et al.*, 2013). Os SAE's também auxiliam na redução do pico de demanda, evitando a ultrapassagem do valor contratado com a concessionária e possíveis impostos relacionados, o que reduz custos na conta de energia. As baterias podem ser carregadas previamente e descarregadas em momentos de aumento de carga do (MARIANO *et al.*, 2021), além de permitir o controle da transferência de potência ativa por meio do ponto de conexão comum (CANTANE *et al.*, 2020).

Uma outra vantagem é a possibilidade de usar sistemas híbridos de energia em relação a forma como ela será utilizada. Ou seja, utilizar o sistema conectado a rede e ligado às baterias, unindo autonomia e praticidade (COSTA; BORTONI, 2016).

No tocante ao uso do SAE, é possível utilizar de inteligência artificial para desenvolver

um algoritmo de arbitragem de carga para determinar a melhor forma de utilizar a bateria. (FRANCISCO, 2018) O presente trabalho usa a técnica Algoritmo Genético (GA) e Evolução Diferencial (ED). A escolha pela utilização da evolução diferencial em conjunto do algoritmo genético se baseia na similaridade entre ambos os métodos, já que são classificados como algoritmos evolutivos, conforme mencionado por Rainer Storn (STORN; PRICE, 1997). Além disso, diversas pesquisas já realizaram comparações ou associações entre esses algoritmos em diferentes cenários, como nos estudos de Amritpal Singh (SINGH; KHAMPARIA, 2020), N Lukman (LUKMAN *et al.*, 2021), Sotirios Vardakos (VARDAKOS *et al.*, 2012) e Cao Erbao (ERBAO *et al.*, 2008). Tais estudos indicam que o desempenho dos algoritmos pode variar de acordo com o tipo de problema enfrentado, evidenciando a importância de selecionar o método mais adequado para garantir a eficiência e eficácia da solução. Além disso, há o objetivo de integrar os dois métodos para criar um algoritmo de otimização, sendo outro propósito do estudo comparar o desempenho dessas técnicas no problema proposto, tanto sob uma perspectiva financeira quanto técnica.

Um algoritmo genético básico envolve uma comunidade de indivíduos, representando conjuntos potenciais de soluções para um problema, em várias etapas de desenvolvimento (gerações). Inicialmente, uma população é gerada de forma aleatória e, em seguida, um ciclo é executado, onde os operadores do algoritmo genético, como seleção, cruzamento e mutação, são aplicados a cada geração, seguindo um processo semelhante à seleção natural, até que um critério de convergência seja alcançado.(ALMEIDA; KAGAN, 2011)

A Evolução Diferencial utiliza os conceitos fundamentais dos algoritmos genéticos, nos quais uma população de soluções potenciais evolui ao longo de várias gerações para se aproximar da solução ótima. No entanto, o DE se distingue pelo emprego de operadores de mutação diferencial e cruzamento, que têm a função de explorar o espaço de busca de maneira eficaz e eficiente(SHI *et al.*, 2014).

Tendo em vista as informações apresentadas, o presente trabalho busca desenvolver simulações utilizando inteligência artificial para observar seus efeitos em um sistema de armazenamento de energia associado a usina solar fotovoltaica na Universidade Federal Rural do Semi-Árido, fazendo a análise financeira observando a economia diária do sistema na universidade, além de trazer o comparativo do desempenho de ambos os métodos de inteligência artificial já mencionados. Vale ressaltar que o presente trabalho trás uma metodologia semelhante a de Francisco (2018), em que sua contribuição está presente na adição de energias renováveis ao problema e

mudança de localização o que implica na alteração da forma em que o faturamento de energia é feito, além de utilizar um novo método de otimização para resolver o problema.

## 1.1 Proposta da Pesquisa

### 1.1.1 Proposta da Ferramenta de Otimização de energia

Este estudo propõe o uso de inteligência artificial para determinar a utilização ótima do sistema de armazenamento de energia. A abordagem é baseada no trabalho de Francisco (2018), utilizando algoritmo genético e evolução diferencial. O objetivo da ferramenta é reduzir os custos oriundos da utilização de energia da rede elétrica, colocando como principais dados de entrada: o perfil de consumo de energia elétrica, o perfil de geração de energia solar, os dados do banco de baterias como vida útil e potencia nominal.

## 1.2 Objetivos

Este trabalho tem como objetivo principal desenvolver uma ferramenta capaz de simular o funcionamento do sistema de armazenamento de energia, em especial na Universidade Federal Rural do Semi-Árido, no aspecto da arbitragem de tarifas de consumo, afim de reduzir os custos com energia elétrica, obtendo a economia para cada dia analisado em reais (R\$), além de realizar o comparativo de métodos heurísticos que melhor se comportou para alcançar o objetivo principal do trabalho.

## 1.3 Resumo dos Capítulos

Diante do exposto, esta dissertação encontra-se organizada da seguinte forma:

- **Capítulo 1:** Este capítulo apresentou uma visão geral sobre o tema que será visto durante toda a dissertação, com o objetivo de introduzir o leitor ao assunto proposto e esclarecer os objetivos principais e secundários a serem alcançados.
- **Capítulo 2:** No capítulo 2, será feita uma exploração mais aprofundada dos temas trabalhados no capítulo 1, abordando todos os conceitos fundamentais necessários para compreender a metodologia que será apresentada e os resultados obtidos.
- **Capítulo 3:** Esta seção é a responsável por apresentar a metodologia usada no trabalho, ou

seja, os detalhes do desenvolvimento da ferramenta de otimização para controle inteligente de baterias utilizando os métodos de algoritmo genético de evolução diferencial.

- **Capítulo 4:** Nesse capítulo, será apresentado os resultados obtidos pela implementação numérica da ferramenta de otimização, bem como a análise comparativa dos métodos de inteligência artificial propostos.
- **Capítulo 5:** Por fim, aqui é feita as considerações a respeito dos resultados obtidos além de algumas sugestões para continuação da pesquisa em trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

Neste capítulo, serão abordados os conceitos fundamentais e as definições matemáticas relacionadas ao funcionamento dos sistemas de armazenamento de energia e aos métodos de inteligência artificial (IA). Será detalhado o funcionamento geral desses sistemas, explicando cada componente existente, além de discutir os diferentes tipos de armazenamento de energia. No que diz respeito às IA, partiremos das referências originais para explicar seu funcionamento, comentando suas particularidades e similaridades. Também será abordado o conceito de arbitragem de tarifas e o software utilizado para realizar as simulações.

### 2.1 Sistemas de Armazenamento de Energia: Tecnologias em geral

Antes de entrar propriamente nos sistemas de armazenamento de energia por bateria, também conhecido por sua sigla em inglês BESS (*Battery Energy Storage System*), será comentado sobre as tecnologias de armazenamento de energia de modo geral e suas aplicações. Além de comentar sobre os subsistemas que envolve a construção de um BESS.

#### 2.1.1 Tecnologias para armazenar energia

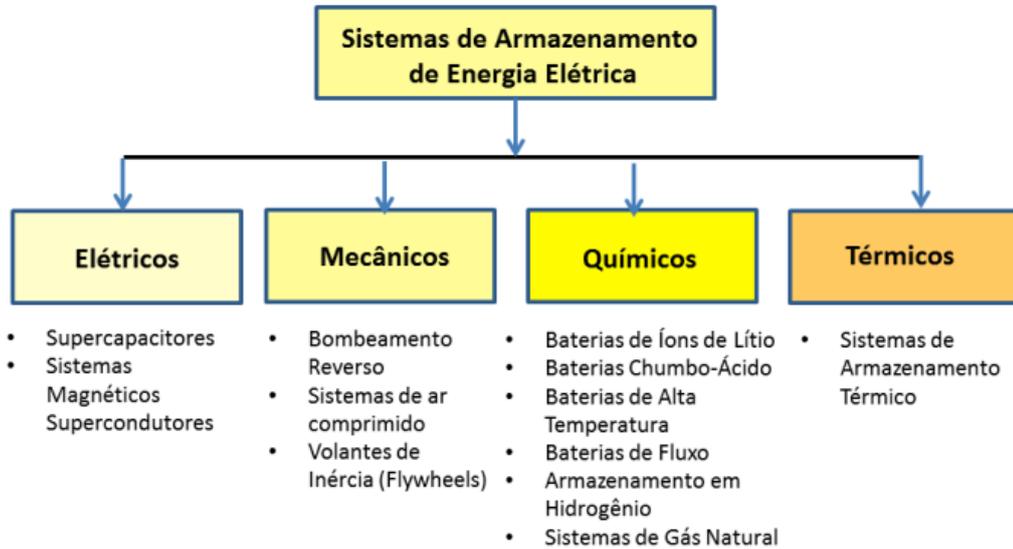
Nessa sub sessão, será comentado sobre as principais tecnologias de armazenamento e suas aplicações, para tal, conforme SILVA (2018) é necessário primeiro abordar os termos técnicos que serão abordados durante a explanação através da tabela 1.

Além disso, é necessário fazer uma classificação geral dessas tecnologias levando em consideração a natureza do princípio de funcionamento. Na figura 1, é ilustrado essa classificação e exemplos de tecnologias correspondentes a cada tipo. Entretanto, visando uma abordagem mais objetiva, será tratado somente das tecnologias mais comuns em termos de utilização.

##### 2.1.1.1 Usina Hidrelétrica Reversível

Segundo Vian *et al.* (2021), para que uma usina hidrelétrica reversível funcione, ela deve possuir dois reservatórios de armazenamento de água: um na parte inferior e outro na parte superior da usina. A operação de carga ocorre quando a água é bombeada do reservatório inferior para o superior, enquanto a descarga acontece no sentido inverso, do superior para o inferior. Durante esse processo, a água passa por uma turbina, realizando a conversão de energia mecânica

Figura 1 – Tecnologias de Armazenamento de Energia

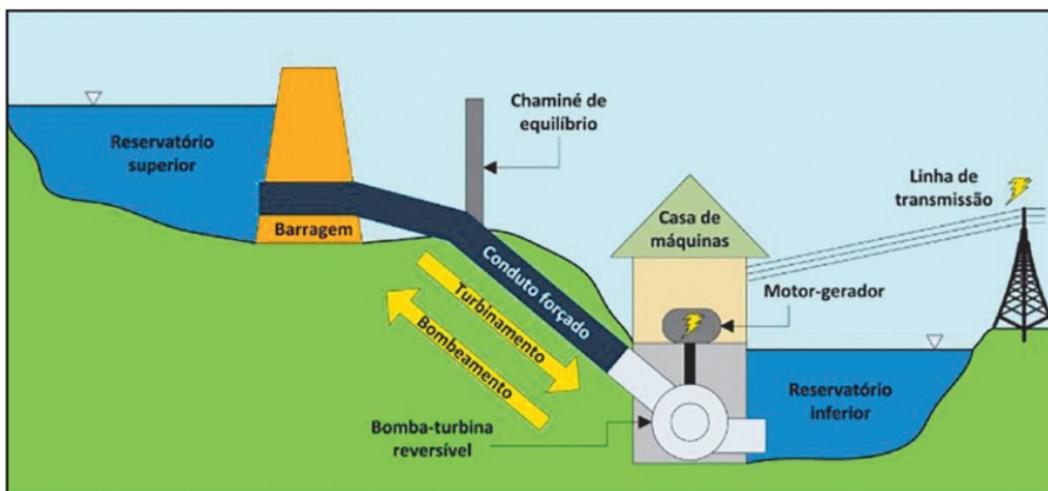


Fonte: Bueno e Brandao (2016).

em energia elétrica. A quantidade de energia armazenada depende da diferença de altura entre os reservatórios e do volume total de água disponível (LUO *et al.*, 2015).

Vale destacar que as usinas hidrelétricas reversíveis representam 97% da capacidade global de armazenamento de energia, devido à sua alta capacidade de armazenagem, que varia entre 500 e 8000 MWh. Além disso, essas usinas possuem uma longa vida útil, que pode durar de 20 a 80 anos, com eficiência entre 65% e 87%, e suportam aproximadamente 15.000 ciclos de vida, o que contribui para sua predominância na tecnologia de armazenamento de energia (CHEN *et al.*, 2009; BEAUDIN *et al.*, 2010). Na figura 2, é possível ver o esquema dessa tecnologia.

Figura 2 – Esquema de uma usina hidrelétrica reversível



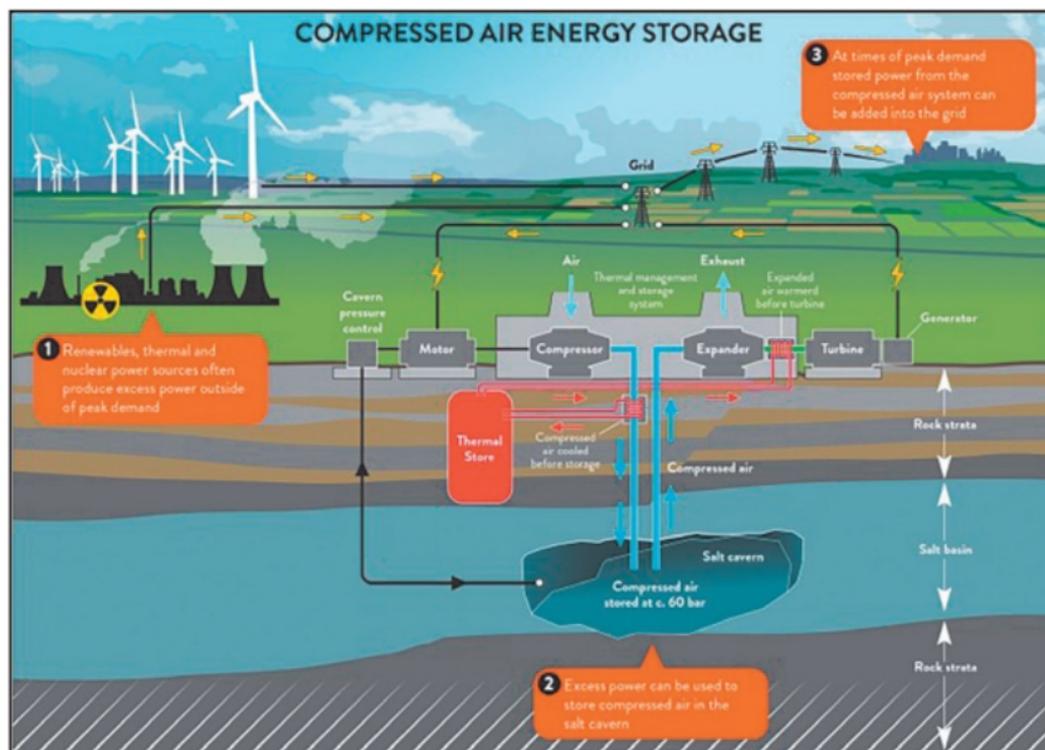
Fonte: Canales *et al.* (2015).

### 2.1.1.2 Armazenamento de Energia em Ar Comprimido

Segundo Vian *et al.* (2021), o princípio de funcionamento do sistema de ar comprimido é similar ao das turbinas a gás, com a principal diferença de que o ar, antes de ser direcionado para a turbina, passa por etapas de compressão, armazenamento e aquecimento. As fases de compressão e armazenamento correspondem ao ciclo de carga, onde o ar é captado do ambiente e comprimido a determinadas pressões por meio de um compressor, sendo posteriormente armazenado em um reservatório. Já a fase de aquecimento refere-se ao ciclo de descarga, no qual o ar comprimido é recuperado e misturado com gás natural, sendo então expandido em turbinas de alta pressão. A energia resultante da explosão é convertida em eletricidade por meio de um gerador (DÍAZ-GONZÁLEZ *et al.*, 2012; SABIHUDDIN *et al.*, 2014).

O sistema de armazenamento por ar comprimido compartilha características técnicas igualmente atraentes ao PHS, como alta eficiência (variando entre 57% e 89%), ausência de taxa de autodescarga e uma longa vida útil, que pode durar de 20 a 40 anos. Além disso, ele se destaca por ser mais viável economicamente e causar menor impacto ambiental durante sua construção. (CHEN *et al.*, 2009; BEAUDIN *et al.*, 2010). Observe na figura 3 o esquema da usina a ar comprimido.

Figura 3 – Esquema de uma usina a ar comprimido



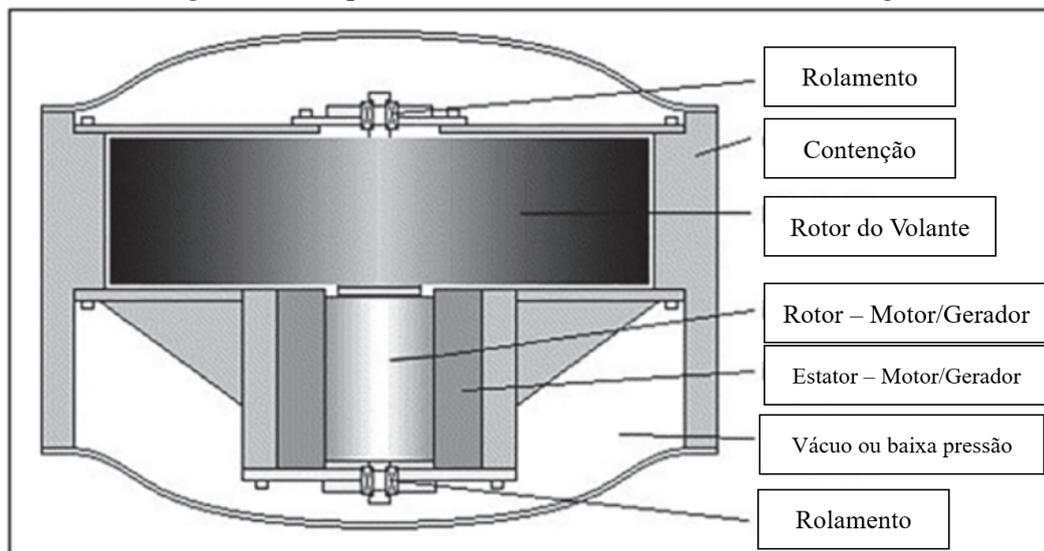
Fonte: Canales *et al.* (2015).

### 2.1.1.3 Volante de Inércia (FLYWHEEL)

O princípio de funcionamento dos volantes de inércia envolve o uso de uma máquina elétrica que aplica torque na mesma direção da rotação, aumentando a velocidade do rotor e armazenando energia (quando opera como motor). Para liberar a energia armazenada, a máquina elétrica inverte o sentido de seu campo magnético e atua como gerador, diminuindo a velocidade do volante. As tecnologias mais avançadas desse sistema são capazes de fornecer energia em sua potência nominal por até 4 horas, com uma eficiência superior a 86% (CANALES *et al.*, 2015).

Dentre suas características operacionais tem-se: elevada quantidade de ciclos (podendo ultrapassar 20.000), longa vida útil (aproximadamente 15 anos), alta densidade de potência (5.000 W/L) e eficiência significativa (entre 70% e 96%). Adicionalmente, possui características vantajosas, como baixo custo de manutenção, flexibilidade quanto à profundidade de descarga (podendo ser descarregado completamente) e a capacidade de operar em diversos tipos de climas. No entanto, uma de suas desvantagens é apresentar uma das maiores taxas de autodescarga entre os sistemas de armazenamento de energia (variando de 24% a 100%), especialmente no modo de espera (CHEN *et al.*, 2009; LUO *et al.*, 2015; BOLUND *et al.*, 2007). Na figura 22 tem-se o esquema de um volante armazenador de energia.

Figura 4 – Esquema de um volante armazenador de energia



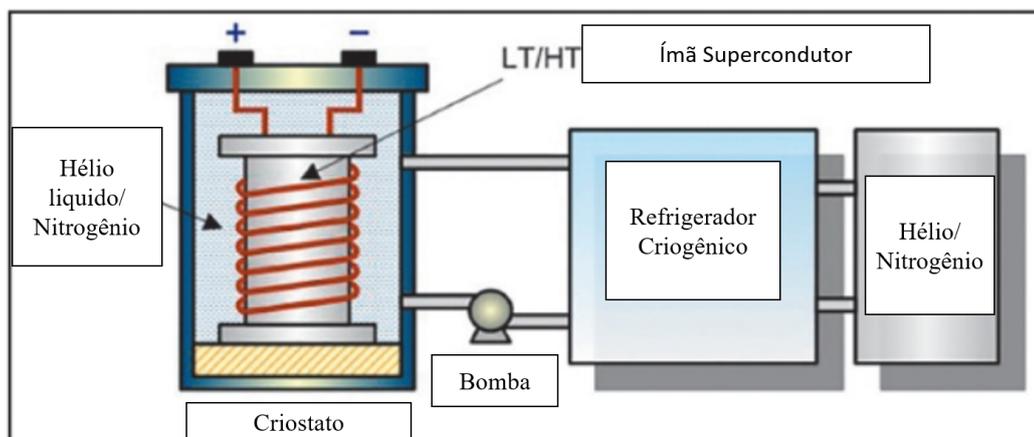
Fonte: Adaptado de Bolund *et al.* (2007).

#### 2.1.1.4 Bobinas Supercondutoras (SMES)

A sigla SMES é oriunda do inglês que significa *Superconducting Magnetic Energy Storage*, segundo Kumar (2015) é possível citar algumas vantagens como sua elevada eficiência (superior a 90%) e o tempo de resposta rápido (inferior a 100 ms) são características destacáveis. No entanto, a alta demanda de energia necessária para manter a bobina na temperatura crítica de supercondução, além do custo elevado para a aquisição dos fluidos, permanecem como desvantagens significativas desta tecnologia (Energy Storage Sense, 2014). Seu principal potencial de uso está relacionado à qualidade de energia, pois os custos elevados limitam sua aplicação para o armazenamento de grandes quantidades de energia.

De acordo com Vian *et al.* (2021) o funcionamento dessa tecnologia acontece da seguinte forma: as bobinas supercondutoras produzem energia ao permitir a passagem de corrente através de uma bobina supercondutora resfriada a uma temperatura criogênica (abaixo de  $-150\text{ }^{\circ}\text{C}$ ), inferior à sua temperatura crítica de supercondução. A energia é armazenada na forma de um campo magnético gerado pela corrente contínua (CC) que circula continuamente pela bobina, devido à resistência elétrica extremamente baixa do material condutor. Para o resfriamento dessas baterias, geralmente são utilizados hélio líquido (4,2 K) ou hélio superfluido (1,8 K). A carga e descarga da bobina é realizada por meio de um inversor/retificador, com uma eficiência entre 97% e 98%. A eficiência total da bobina supercondutora pode ultrapassar 95%. Na figura 5 é possível ver o esquema do SMES.

Figura 5 – Esquema de um SMES



Fonte: Adaptado de Energy Storage Sense (2014).

### 2.1.1.5 Super Capacitores

De acordo com González *et al.* (2016), os supercapacitores, ou ultracapacitores, possuem entre 10 e 100 vezes mais capacidade de energia em comparação com capacitores eletrolíticos de mesmo volume, além de suportarem um número significativamente maior de ciclos de carga e descarga (cerca de 500 milhões) do que baterias recarregáveis e oferecerem maior velocidade de descarga. No entanto, sua principal limitação é a baixa tensão de operação da célula, que deve ser mantida para evitar a decomposição química dos eletrólitos. Eles podem ser utilizados na rede elétrica para regulação de frequência, suavização da variabilidade das fontes renováveis e melhoria da qualidade de energia.

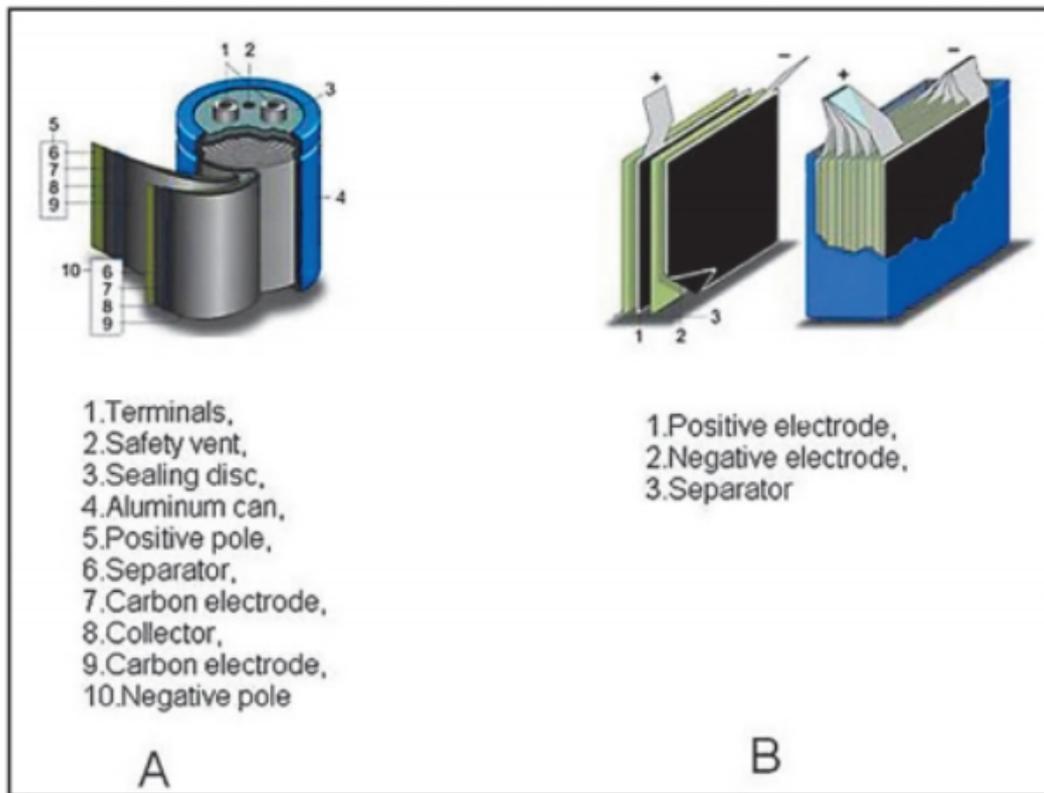
Uma estrutura convencional de capacitor consiste em duas placas metálicas, representando o cátodo e o ânodo, separadas por um material dielétrico. No supercapacitor, tanto o cátodo quanto o ânodo são feitos de material poroso, e, no lugar do dielétrico, há um eletrólito e uma membrana porosa que serve como separador entre as duas placas(DÍAZ-GONZÁLEZ *et al.*, 2012; LUO *et al.*, 2015). É graças ao material poroso que os supercapacitores conseguem armazenar grandes quantidades de energia, o que os torna capazes de operar com altas potências(SABIHUDDIN *et al.*, 2014). Os supercapacitores se destacam por sua alta ciclagem (de 10.000 a 1.000.000 de ciclos), tempo de resposta muito rápido (inferior a segundos), alta eficiência (85-99%) e boa vida útil (entre 5 e 20 anos)(CHEN *et al.*, 2009; SABIHUDDIN *et al.*, 2014). Essa tecnologia é limitada a aplicações de curta duração devido à alta taxa de auto descarga (20-40%), sendo utilizada em regulação de tensão, reserva girante, qualidade de energia, controle de demanda e confiabilidade(LUO *et al.*, 2015).

Os supercapacitores consistem em dois eletrodos eletricamente isolados por uma membrana semipermeável, que atua como separador(VANGARI *et al.*, 2013). Tanto os eletrodos quanto o separador são banhados com uma solução, o eletrólito, que possibilita o fluxo de corrente iônica entre os eletrodos e impede a passagem de corrente elétrica que descarregaria a célula. Na figura 6 é possível ver o esquema de construção dos supercapacitores.

### 2.1.1.6 Sistemas Eletroquímicos (Baterias)

É o armazenador de energia mais comum no cotidiano da população, encontrados em aparelhos de celular, computadores e outros equipamentos eletrônicos. As baterias operam com base no mesmo princípio das pilhas, onde reações químicas de redução e oxidação geram

Figura 6 – Esquema de construção dos Supercapacitores



Fonte: (GABAY, 2013).

tensão e corrente elétrica. O campo da eletroquímica é dedicado ao estudo das interações entre reações químicas e eletricidade. Os potenciais de energia gerados por essas reações podem ser encontrados nas tabelas eletroquímicas (VIAN *et al.*, 2021). Além disso, as baterias podem ser divididas em primárias (não recarregáveis) e secundárias (recarregáveis) (CROMPTON, 2000). Os principais tipos de baterias tradicionais são: Chumbo ácido e Li-íon.

A bateria de chumbo-ácido apresenta algumas características técnicas relevantes, como alta eficiência energética (cerca de 63-90%) e uma baixa taxa de auto descarga (0,1-0,3% ao dia). No entanto, suas desvantagens incluem um ciclo de vida limitado (entre 250 e 1500 ciclos) e uma baixa densidade de energia (50-80 Wh/L). Além disso, essas baterias têm desempenho insatisfatório em ambientes de baixa temperatura, são tóxicas, apresentam um carregamento lento e não oferecem uma boa taxa de profundidade de descarga (CHEN *et al.*, 2009; HU *et al.*, 2017; LUO *et al.*, 2015; SABIHUDDIN *et al.*, 2014).

No que diz respeito às baterias de Li-íon, elas possuem características técnicas notáveis, como uma excelente densidade de energia (200-500 Wh/L), alta eficiência (70-100%), um ciclo de vida satisfatório (mais de 2500 ciclos) e a capacidade de carregar e descarregar rapidamente. No entanto, essas baterias apresentam preocupações relacionadas à segurança, pois podem

explodir e incendiar em casos de sobrecarga, dano físico ou aumento de temperatura (CHEN *et al.*, 2009; HU *et al.*, 2017; LUO *et al.*, 2015; SABIHUDDIN *et al.*, 2014).

#### 2.1.1.7 Sistemas Térmicos

É possível afirmar que os sistemas térmicos para armazenar energia elétrica ainda estão em fase de aprimoramento, com características experimentais (BUENO; BRANDAO, 2016). Isso ocorre devido a conversão de energia térmica em outras formas de energia como elétrica e mecânica ainda ser muito difícil por possuir baixa eficiência e necessitar de temperaturas muito elevadas para seu funcionamento.

Os motores Stirling, que aproveitam calor de fontes externas, têm uma eficiência média de apenas 15%. Por outro lado, as turbinas mais eficientes, operando em condições de alta pressão e temperaturas elevadas, podem alcançar até 60% de eficiência. Armazenar grandes quantidades de energia térmica em temperaturas muito altas (até 600°C) é um desafio técnico significativo. Nas usinas termosolares, já foram testados sistemas com sal fundido para guardar o calor, porém esses sistemas são caros, complexos de operar e apresentam eficiência reduzida, devido às perdas térmicas e ao consumo energético necessário para manter a infraestrutura funcionando (BUENO; BRANDAO, 2016).

#### 2.1.2 Armazenamento de Energia para uma Determinada Aplicação

Para identificar a tecnologia mais adequada para uma determinada aplicação, é fundamental considerar uma série de critérios que orientarão essa escolha. Os principais fatores a serem analisados incluem a natureza da tarefa, sua duração e a frequência de uso (SILVA, 2018).

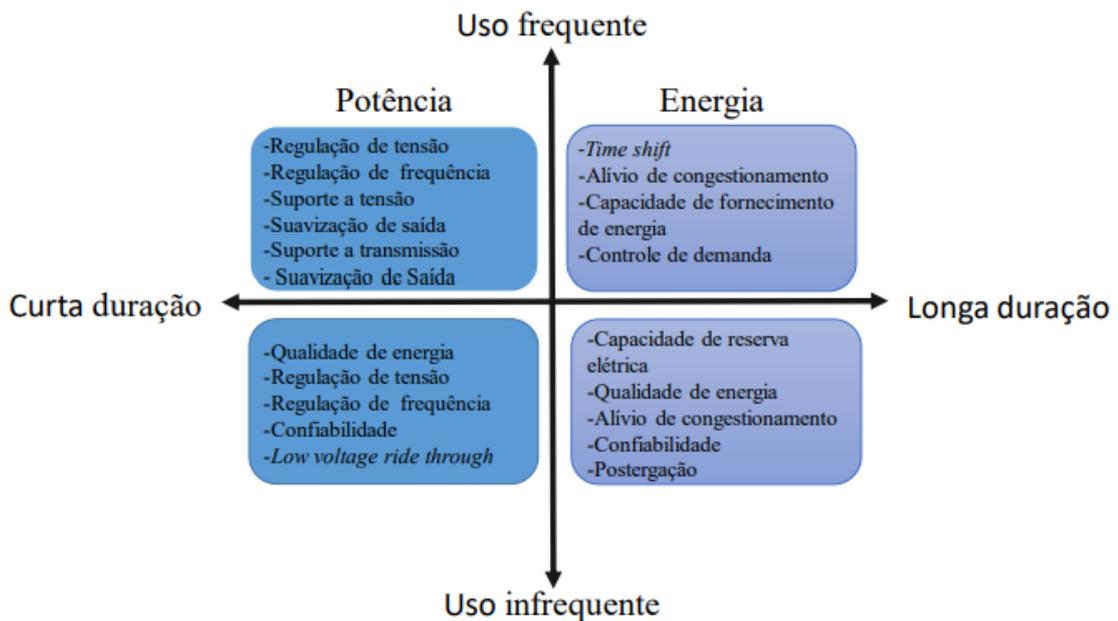
A natureza de uma tarefa pode ser descrita em termos de energia, medida em Watt-hora (Wh), que corresponde à quantidade total de potência fornecida a um sistema ao longo de um determinado período. Alternativamente, pode ser definida em termos de potência, medida em Watt (W), representando a velocidade com que a energia é transferida ou consumida dentro de um intervalo de tempo. Em resumo, energia refere-se ao total de potência entregue durante um período, enquanto a potência indica a taxa com que essa energia é modificada ou utilizada (SILVA, 2018).

A duração refere-se ao período de tempo necessário para a execução de um serviço, podendo variar entre curto prazo, quando a tarefa é concluída em segundos ou minutos, e longo prazo, quando se estende por várias horas ou até dias (SILVA, 2018).

A frequência de uma aplicação refere-se ao número de vezes que ela se repete dentro de um determinado período. Ela pode ser considerada frequente quando ocorre mais de vinte vezes por ano, ou infrequente, quando acontece menos de vinte vezes por ano (SILVA, 2018).

Na figura 7 é ilustrado algumas aplicações em função dos critérios comentados anteriormente.

Figura 7 – Classificação dos serviços com base na natureza, duração e frequência



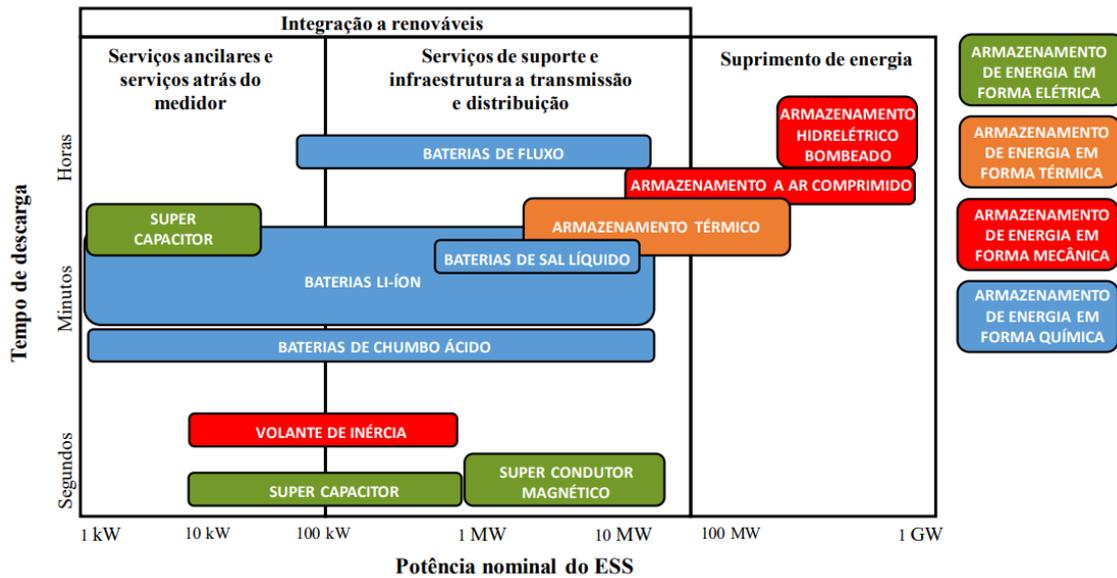
Fonte: Adaptado de Carnegie *et al.* (2013).

Além dessa classificação dos serviços, também existe a classificação dos parâmetros de funcionamento em função da natureza, duração e frequência, conforme é possível ver na tabela 2.

Por fim, outro fator crucial a ser considerado na escolha do tipo de armazenamento é a potência nominal desejada para a operação. A figura 8 ilustra os diferentes tipos de tecnologia de armazenamento em função da potência de atuação e do tempo de descarga.

Observando a Figura 8, pode-se afirmar que as baterias são as mais versáteis entre as tecnologias de armazenamento, sendo aplicáveis em uma ampla gama de situações, desde o uso em residências até em grandes usinas geradoras de energia (SILVA, 2018). As baterias têm se consolidado como uma opção cada vez mais atraente para sistemas de armazenamento, especialmente em aplicações voltadas à integração com fontes renováveis. Isso se deve à sua capacidade de atender a diversas demandas, ao avanço contínuo da tecnologia, à redução progressiva dos custos de produção e à sua característica de portabilidade (RENEWABLE *et al.*,

Figura 8 – Faixas de potência e tempo de descarga para cada tecnologia de armazenamento de energia (ESS)



Fonte: Adaptado de Barbour (2018).

2017).

A tecnologia adotada neste trabalho é a de baterias, utilizando o Sistema de Armazenamento de Energia por Baterias (BESS) para a arbitragem de carga e descarga. Na Sessão 2.1.3, serão discutidos em maior detalhe esse sistema e seus componentes.

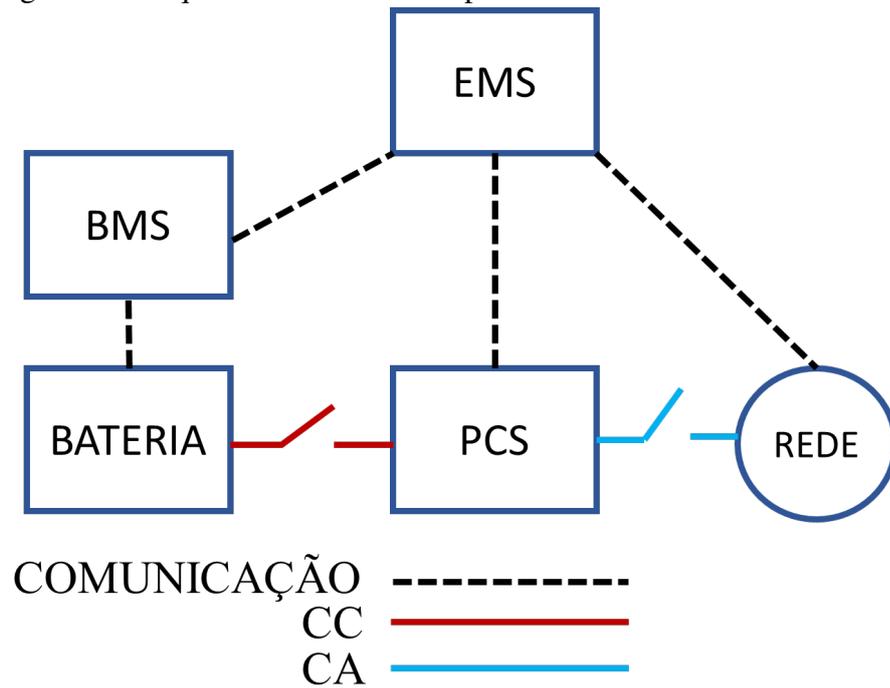
### 2.1.3 Componentes do BESS

Nesta seção, serão apresentados os principais componentes de um Sistema de Armazenamento de Energia em Baterias, detalhando seu funcionamento e demonstrando como eles são integrados para formar o sistema completo. A Figura 9 ilustra um esquema básico com os componentes que serão discutidos.

#### 2.1.3.1 Bateria

Como já mencionado, as baterias armazenam energia por meio de reações químicas, permitindo que sejam carregadas ou descarregadas conforme necessário. A menor unidade de armazenamento é a célula. Para o funcionamento adequado da bateria, é essencial que ela opere dentro de sua tensão nominal, a qual varia conforme o estado de carga. Portanto, é fundamental monitorar constantemente as células para evitar danos e garantir a longevidade do sistema (Adafruit Learning System, 2024). Na figura 10, é possível visualizar o comportamento da tensão

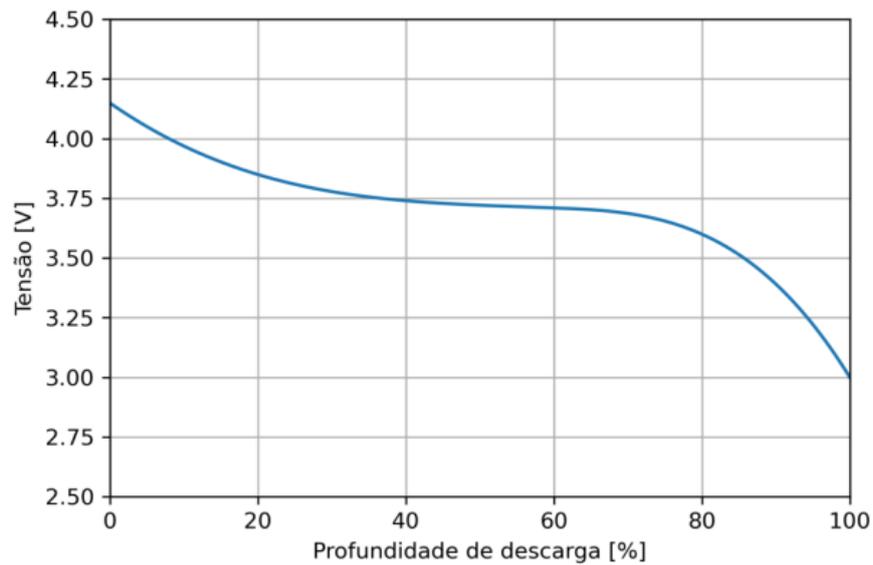
Figura 9 – Esquema básico dos componentes do BESS



Fonte: Autoria própria.

nominal da célula em função do decaimento do seu estado de carga (GOULART *et al.*, 2021).

Figura 10 – Perfil de tensão em função da profundidade de descarga.



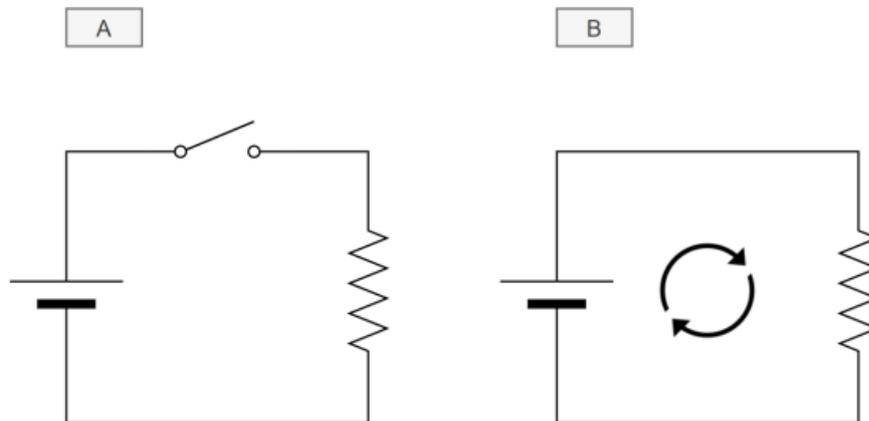
Fonte: (GOULART *et al.*, 2021)

### 2.1.3.2 BMS

Para garantir o controle correto e preciso do funcionamento das baterias, o Sistema de Gerenciamento de Baterias (BMS) é um subsistema fundamental do BESS, responsável por monitorar individualmente cada célula do banco de baterias. Ele previne eventuais danos que possam comprometer o desempenho ou a integridade do sistema (RANAWAT; PRASAD, 2018).

Uma das funções principais do BMS é garantir o balanceamento de tensão entre as células. Esse processo é essencial para que todas as células permaneçam em níveis semelhantes de tensão, permitindo que sejam carregadas de forma completa e uniforme. Para isso, o sistema descarrega individualmente as células que excedem um determinado limite superior de tensão, utilizando um ou mais resistores ativados para criar um fluxo de corrente de descarga. Nos momentos A e B da Figura 11, observa-se a inserção do resistor de balanceamento no circuito, o que gera uma corrente elétrica. Essa corrente dissipa gradualmente a energia armazenada na célula, reduzindo a tensão nos terminais e aproximando-a da média das outras células do sistema (NIZAM *et al.*, 2019).

Figura 11 – Balanceamento de uma célula de bateria.



Fonte: (GOULART *et al.*, 2021)

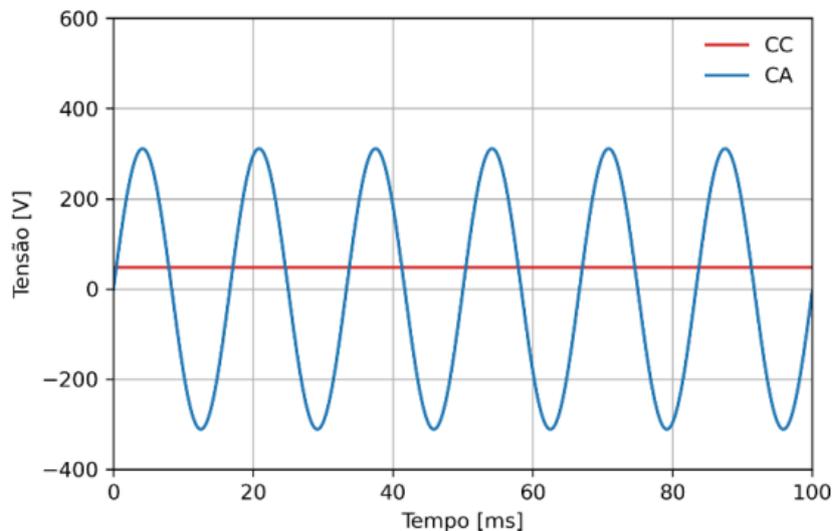
Além disso, o BMS é capaz de medir o estado de carga (SoC) da bateria e monitorar sua condição de saúde (SoH). Em veículos elétricos por exemplo, essa funcionalidade é particularmente importante, pois esses parâmetros fornecem informações cruciais sobre a longevidade e a autonomia do veículo (MANTHOPOULOS; WANG, 2020).

### 2.1.3.3 PCS

O PCS (Power Conversion System) é, de forma resumida, um inversor de energia responsável pela conversão bidirecional, transformando corrente alternada (CA) em corrente contínua (CC) e vice-versa. Conforme Goulart *et al.* (2021), em sistemas de armazenamento de energia de médio e grande porte, o dispositivo anteriormente chamado de inversor passou a ser conhecido como PCS. Isso ocorre porque a inteligência, antes integrada no inversor, agora é separada e externalizada, devido à maior complexidade desses sistemas em larga escala. Cada projeto possui características únicas, o que exige que o sistema de controle seja desenvolvido de forma mais personalizada. Uma das principais diferenças entre o PCS e os inversores fotovoltaicos convencionais é a capacidade de realizar a conversão bidirecional de corrente, permitindo tanto o carregamento das baterias (por retificação) quanto a descarga (por inversão).

A presença do PCS é importante em razão da necessidade da energia estar em corrente contínua para que seja armazenada, e ao mesmo tempo é preciso fazer o processo inverso para que a energia seja utilizada na rede de distribuição e nas cargas que são comumente usadas. A Figura 12 ilustra um sistema em que a energia contínua (CC) de um banco de baterias de 48 V é convertida para 220 V em corrente alternada (CA), correspondendo a 311 V de pico. Esses valores são bastante comuns em diversos sistemas de armazenamento que utilizam baterias de chumbo-ácido (MUELLER *et al.*, 2020).

Figura 12 – Inversão de 48 V CC para 220 V CA..



Fonte: (GOULART *et al.*, 2021)

#### 2.1.3.4 EMS

Por fim, o EMS (Energy Management System), trata-se do sistema que gerencia todo o conjunto, encarregado de coletar dados, tomar decisões e intervir no BESS. Sua função é assegurar o funcionamento adequado e a segurança de todos os componentes que fazem parte do sistema. Em geral, o Sistema de Gerenciamento de Energia (EMS) é implementado com a ajuda de um Controlador Lógico Programável (CLP) ou outra plataforma de automação industrial. Os CLPs são versáteis, possuindo múltiplas entradas e saídas, tanto analógicas quanto digitais, além de suportarem diversos protocolos de comunicação. Essa flexibilidade e a alta confiabilidade dos CLPs tornam-nos ideais para atuar como o "cérebro" de um BESS (WAGO, 2021).

## 2.2 Inteligência Artificial e métodos heurísticos

Segundo Lopes *et al.* (2014), o termo Inteligência Artificial (IA) refere-se a um conjunto de processos computacionais que, se executados por um ser humano, seriam considerados atos inteligentes. Esse conceito é amplo e pode ser definido de várias formas, refletindo as diferentes interpretações da palavra "inteligência". Entre os temas associados ao desenvolvimento da IA estão os métodos heurísticos, que desempenham um papel importante na solução de problemas complexos de forma eficiente.

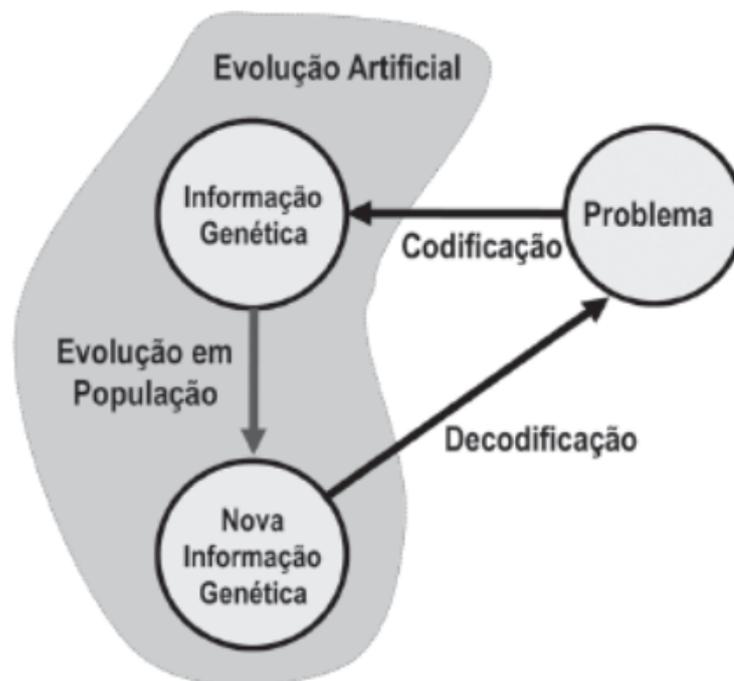
Os algoritmos computacionais enfrentam um grande desafio ao tentar fornecer soluções exatas para problemas NP-difíceis de grande escala. Problemas NP-difíceis são uma classe de problemas computacionais que são pelo menos tão difíceis quanto os problemas mais difíceis da classe NP. A classe NP (tempo polinomial não determinístico) é um conjunto de problemas de decisão (com respostas "sim" ou "não") para os quais uma solução proposta pode ser verificada rapidamente (em tempo polinomial) por um algoritmo determinístico. Esses problemas são caracterizados pelo aumento significativo no tempo ou na memória necessários para encontrar uma solução exata à medida que o tamanho da entrada de dados cresce. Mesmo com condições específicas, a resolução de um problema NP-difícil demanda recursos computacionais que aumentam exponencialmente com o número de variáveis envolvidas. Em problemas de grande porte, com muitas variáveis de entrada, o tempo de processamento ou a memória necessária para alcançar uma solução exata pode se tornar inviável. Essa limitação revela que os métodos algorítmicos e os computadores atuais enfrentam dificuldades para resolver eficientemente, em muitos casos, problemas NP-difíceis em escalas reais ou desafios de complexidade ainda

maior(GOLDBARG *et al.*, 2017).

Devido à limitação dos métodos exatos, nas últimas décadas houve um esforço considerável para desenvolver e aprimorar estratégias aproximadas e eficientes para resolver problemas de grande escala. Esses métodos aproximativos, conhecidos como heurísticas, têm sido propostos há bastante tempo como uma alternativa para lidar com a complexidade desses problemas. Assim, o termo "heurística" refere-se a um conjunto de estratégias aproximativas para a solução de problemas no contexto da computação(GOLDBARG *et al.*, 2017).

Entre os métodos heurísticos, este trabalho se concentra nos algoritmos evolutivos, com ênfase específica no algoritmo genético e na evolução diferencial. Os Algoritmos Evolucionários (AEs) operam, de maneira geral, de acordo com o esquema ilustrado na Figura 13.

Figura 13 – Evolução da informação genética.



Fonte: (GOLDBARG *et al.*, 2017)

O problema é representado como “informação genética” dentro do paradigma da evolução artificial. Essa informação é submetida a um processo evolutivo para se adaptar às condições do problema, sendo, em seguida, decodificada para gerar soluções. Essa informação genética é disseminada por uma população de indivíduos que evolui segundo regras de seleção e operadores genéticos, como recombinação e mutação. Os indivíduos da população representam propostas de solução para o problema, sejam elas viáveis ou não. A avaliação desses indivíduos orienta o processo de reprodução, favorecendo aqueles que demonstram melhor adequação, de acordo

com os princípios da evolução darwiniana(GOLDBARG *et al.*, 2017).

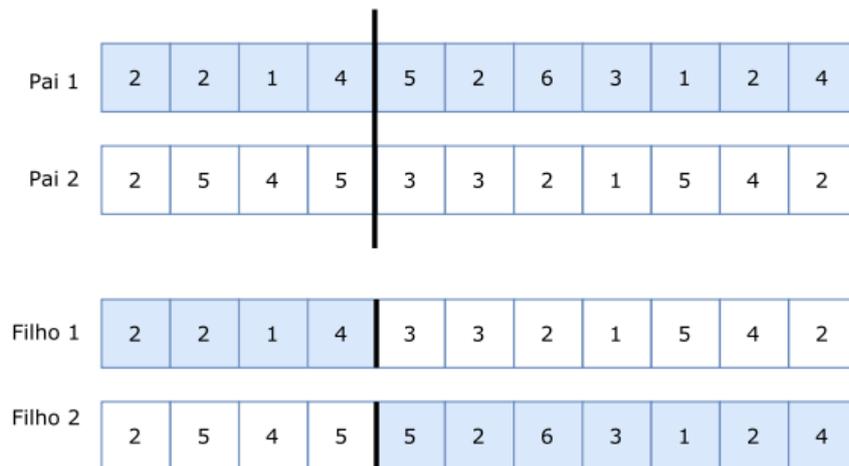
### 2.2.1 Algoritmo Genético (AG)

Como mencionado anteriormente, o algoritmo genético é um algoritmo evolutivo fundamentado na teoria da evolução de Charles Darwin. Desenvolvido por John Henry Holland em 1975, o algoritmo começa com uma população inicial, composta pelos candidatos à solução do problema proposto, que são representados por cromossomos. Esses cromossomos são avaliados por meio de uma função de aptidão, que determina os melhores indivíduos, que, em seguida, passam pelos operadores genéticos utilizando regras probabilísticas para combinar soluções a fim de obter melhorias de qualidade.(LAMBORA *et al.*, 2019). Os operadores são: Seleção, Cruzamento e Mutação.

- Seleção: É o processo em que são escolhidos os indivíduos que passarão para os próximos operadores. As principais formas de seleção incluem(ASSUNÇÃO, 2010):
  - Roulette Wheel Selection: Também conhecida como seleção por roleta, esse método atribui uma probabilidade de seleção a cada indivíduo proporcional à sua aptidão. Indivíduos com melhor desempenho têm maior chance de serem selecionados, mas indivíduos menos aptos ainda têm alguma chance.
  - Ranking: Nesse método, os indivíduos são ordenados de acordo com sua aptidão, e a seleção é feita com base em sua posição no ranking, garantindo uma distribuição mais equilibrada e controlando a probabilidade de seleção dos indivíduos.
  - Torneio: Seleciona um grupo aleatório de indivíduos e realiza uma competição entre eles, escolhendo o mais apto dentro do grupo. Esse método permite um controle simples da pressão seletiva, ajustando o número de competidores por torneio.
- Cruzamento: Combinar a informação genética de dois indivíduos (pais) para gerar novos indivíduos (filhos) com características melhores. Existem diversos métodos de cruzamento, sendo os principais: cruzamento de 1 ponto, n pontos, cruzamento uniforme e cruzamento por média. O método mais comum é o cruzamento de 1 ponto, onde uma posição K do vetor do indivíduo é escolhida aleatoriamente, e a partir desse ponto, os genes dos dois indivíduos são trocados, gerando dois novos descendentes, como ilustrado na figura 14 (com  $K = 4$ )(NÉIA *et al.*, 2013).
- Mutação: O operador de mutação tem como função diversificar a herança genética das populações geradas, modificando um ou mais genes no cromossomo. Isso garante que os

novos indivíduos não sejam idênticos aos seus ascendentes. A introdução de pequenas mutações nos genes evita que o processo se torne totalmente aleatório, permitindo a recuperação de boas características que possam ter sido perdidas durante os processos de seleção e cruzamento (GEN; CHENG, 1999).

Figura 14 – Cruzamento com único ponto.



Fonte: Adaptado de Néia *et al.* (2013)

A Figura 15 apresenta o esquema básico de funcionamento do AG, destacando a posição de cada um dos operadores mencionados anteriormente.

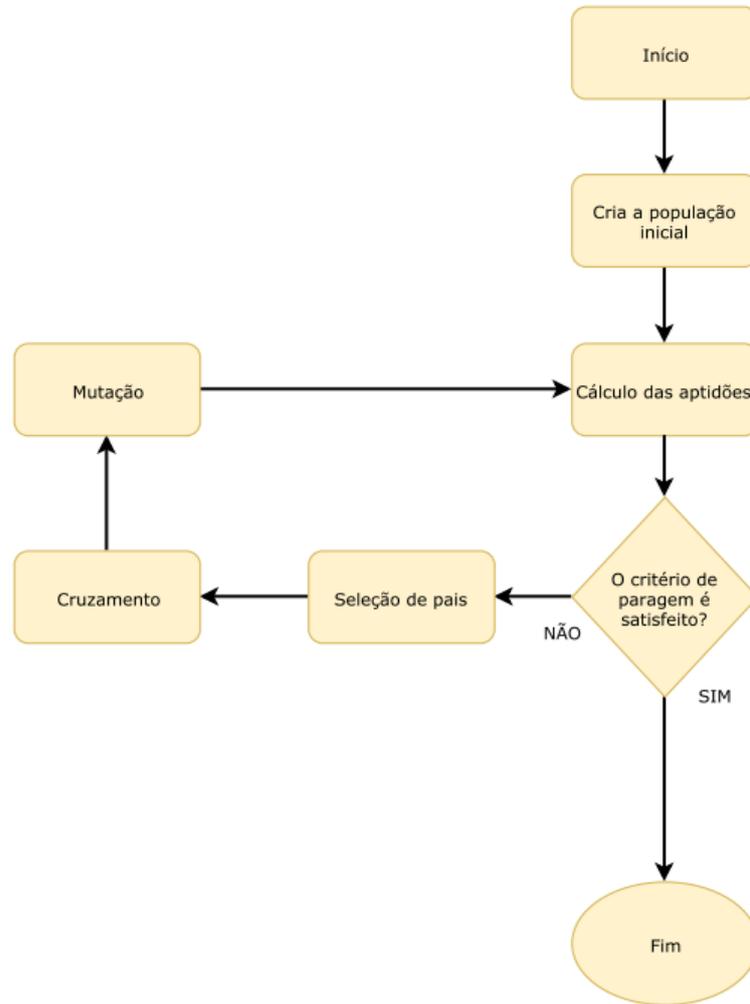
### 2.2.2 Evolução Diferencial (ED)

Segundo Storn e Price (1997), os usuários geralmente exigem que os algoritmos de otimização atendam a certos critérios de desempenho: capacidade de lidar com funções de aptidão não diferenciáveis, paralelização para enfrentar funções de custo intensivas em computação, facilidade de uso com poucas variáveis de controle para guiar o processo de minimização, sendo essas variáveis robustas e de fácil escolha, além de boas propriedades de convergência, ou seja, uma convergência consistente para o mínimo global em tentativas independentes consecutivas.

De modo geral o método evolução diferencial foi desenvolvido com o propósito de cumprir todos os requisitos listados anteriormente. Semelhante ao AG, os operadores do evolução diferencial são: Mutação, Recombinação e seleção.

- Mutação: É um operador responsável por gerar uma nova solução a partir de três vetores aleatórios da população. A equação que corresponde a nova solução gerada (vetor mutante)

Figura 15 – Fluxograma algoritmo Genético.



Fonte: Adaptado de Néia *et al.* (2013)

é dada pela equação 1.

$$v_i = x_1 + F(x_2 - x_3) \quad (1)$$

Onde:

- $v_i$  é o individuo gerado na mutação.
  - $x_1, x_2, x_3$  são vetores escolhidos aleatoriamente.
  - $F$  é um numero constante entre 0 e 2 escolhido pelo programador.
- **Recombinação:** Esse operador, combina o vetor mutante  $v_i$  com o vetor atual  $x_i$  gerando um vetor  $u_i$ . Nesse momento o algoritmo deve calcular a probabilidade de cruzamento através da taxa de cruzamento  $cr$  seguindo a expressão 2.

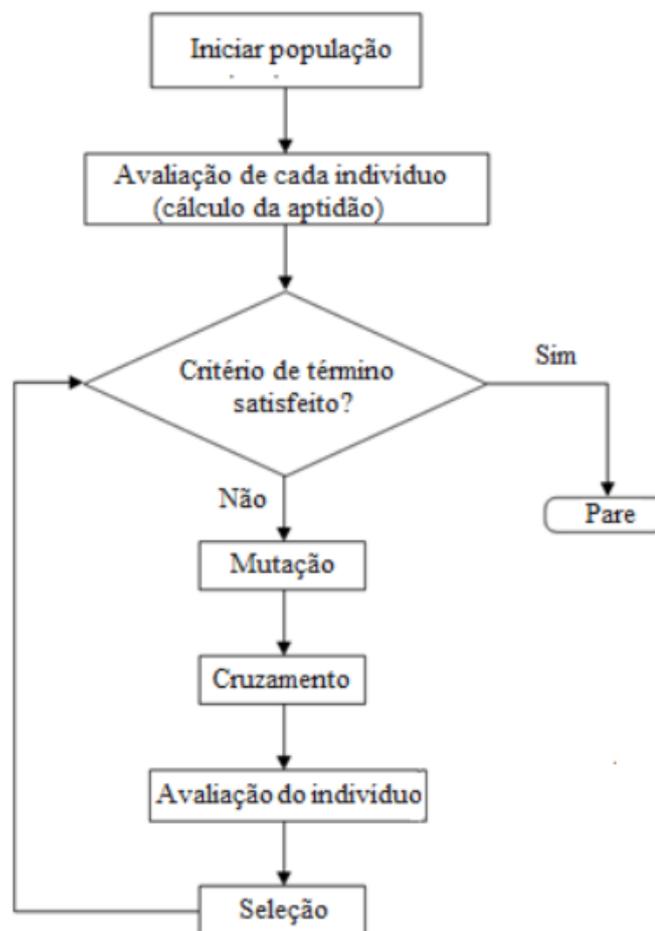
$$v_i = \begin{cases} u_i, & \text{se } \text{rand}(0, 1) \leq CR \text{ ou } j = j_{rand} \\ x_i, & \text{caso contrário} \end{cases} \quad (2)$$

De maneira resumida, a recombinação ocorrerá se o valor gerado pela probabilidade de cruzamento for maior do que o valor definido pela taxa de cruzamento.

- Seleção: Este operador determina se o vetor  $u_i$  substituirá o vetor  $x_i$  na próxima geração. Neste momento, a aptidão do vetor  $u_i$  será avaliada, se for maior do que a do vetor  $x_i$  então  $u_i$  será incorporado à próxima população.

De modo geral, o fluxograma que representa o funcionamento do método evolução diferencial está representado na figura 16.

Figura 16 – Fluxograma Evolução Diferencial.



Fonte: Adaptado de Rosário *et al.* (2012)

### 2.3 arbitragem de Tarifas

Para calcular a fatura de energia elétrica no Brasil, diversos componentes devem ser considerados, incluindo o grupo tarifário e a modalidade escolhida pelo cliente ou determinada pela concessionária. Além disso, é necessário considerar o valor da demanda contratada e outros

encargos (ANEEL, 2022). Neste trabalho, foca-se na explicação dos postos tarifários, uma parcela que a simulação proposta pode controlar, visando simplificar a análise.

Na modalidades tarifárias do grupo A (consumidores atendidos em alta tensão) é aplicado os postos tarifários ponta e fora de ponta. E na Tarifa Branca aplicada ao Grupo B (consumidores atendidos em baixa tensão), aplicam-se os três postos tarifários: ponta, intermediário e fora ponta. Esses postos são definidos pela distribuidora de energia elétrica de cada região com revisão periódica a cada 4 ou 5 anos de acordo com a resolução normativa (REN) nº 1.000/2021 da Aneel (ANEEL, 2022).

- Ponta: refere-se a um intervalo diário de 3 horas consecutivas, exceto aos sábados, domingos e feriados nacionais.
- Intermediário: intervalo de horas correlacionadas com o horário de pico, aplicado apenas às unidades consumidoras que escolhem a Tarifa Branca. Este intervalo pode variar de 1 hora a 1 hora e 30 minutos antes e depois do horário de pico.
- Fora ponta: intervalo diário que abrange horas consecutivas complementares aos horários de pico e intermediário.

## 2.4 Geração de usina solar - Método da insolação

Dentre as possibilidades de calcular a geração de uma usina solar, será explorado nessa sessão o método da insolação proposto em VILLALVA (1983). Este procedimento pode ser utilizado para calcular a energia gerada pelo painel solar, desde que haja dados disponíveis sobre a irradiação solar diária no local de instalação. A expressão que descreve a geração é dado pela equação 3.

$$E_p = E_s A_m \eta \quad (3)$$

Onde:

- $E_p$  energia produzida pelo módulo diariamente [Wh].
- $E_s$  é a insolação diária [Wh/m<sup>2</sup>/dia].
- $A_m$  é a área da Área da superfície do módulo [m<sup>2</sup>].
- $\eta$  é a eficiência do módulo [%].

Tabela 1 – Termos técnicos no contexto dos sistemas de armazenamento de energia

PARÂMETRO	DESCRIÇÃO	UNIDADE
Energia	Trata-se de uma grandeza central em sistemas elétricos, relacionada à capacidade de armazenamento e à energia fornecida ou extraída do sistema de armazenamento de energia (ESS).	kWh
Potência	É uma grandeza física que representa a taxa de transferência de energia por unidade de tempo, podendo ser consumida ou fornecida por um sistema. Relaciona-se à capacidade de realizar trabalho. Em sistemas de armazenamento, um ESS de alta potência libera energia rapidamente, enquanto um de baixa potência possui maior limitação na corrente de descarga.	W
Energia útil	Refere-se à energia efetivamente disponível para uso. Por exemplo, algumas baterias, para aumentar sua vida útil, utilizam apenas 50% de sua capacidade nominal. Nesse caso, a energia útil será limitada a 50% da capacidade total, resultando em um sobredimensionamento do acumulador.	kWh
Duração de descarga	Refere-se ao tempo de descarga de um ESS, determinando sua autonomia. É definido pela relação entre a capacidade de energia e a potência instalada.	kWh/kW ou h
Densidade energética	É a relação entre a energia útil de uma tecnologia e seu volume, indicando a densidade energética do sistema.	kWh/m <sup>3</sup>
Densidade de potência	Refere-se à relação entre a potência instalada de uma tecnologia e seu volume, geralmente expressa em W/m <sup>3</sup> , mas também pode ser apresentada em W/litro.	W/m <sup>3</sup>
Energia específica	É a relação entre a energia fornecida e o peso do sistema de armazenamento.	kWh/kg
Potência específica	É a razão da potência do sistema de armazenamento pelo seu peso.	W/kg
Auto descarga	É a perda de energia de um sistema de armazenamento devido aos processos internos.	%/mês
Ciclo	Uma sequência de carga e descarga do sistema de armazenamento, também conhecido como ciclo de carga/descarga.	Ciclos
Ciclos de vida (Life cycle)	O número de ciclos de carga/descarga que, após completados, o sistema de armazenamento torna-se inoperável para uma determinada aplicação.	Ciclos
Vida útil (Lifetime)	É o tempo de vida de um dispositivo para uma determinada aplicação, antes que o desgaste com o uso o torne inoperável.	Anos
Profundidade de descarga (DOD – Depth of Discharge)	É a porcentagem de energia extraída de um dispositivo de armazenamento em relação à sua energia total, em um determinado regime de descarga. Geralmente, taxas de descarga mais lentas permitem a extração de uma maior quantidade de energia, enquanto correntes mais elevadas resultam em uma extração menor. Esse fator também está relacionado à vida útil de alguns sistemas de armazenamento.	%
Estado de carga (SOC - state of charge)	É a quantidade de energia disponível em relação à capacidade total de armazenamento.	%

Fonte: Adaptado (HUFF *et al.*, 2013).

Tabela 2 – Parâmetros relativos à natureza, duração e frequência de um serviço

	<b>Serviço de energia, longa duração, uso frequente</b>	<b>Serviço de energia, longa duração, uso infrequente</b>	<b>Serviço de potência, curta duração, uso frequente</b>	<b>Serviço de potência, curta duração, uso infrequente</b>
<b>Tempo de descarga</b>	1-24 horas	1-24 horas	Segundos- minutos	Segundos- minutos
<b>Tempo de resposta</b>	Minutos	Minutos	Segundos	Segundos
<b>Ciclo de vida</b>	$\geq 1.000$ ciclos	$\geq 100$ ciclos	$\geq 10.000$ ciclos	$\geq 1.000$ ciclos

Fonte: Adaptado de SILVA (2018)

### 3 MATERIAIS E MÉTODOS

Este capítulo apresenta a metodologia utilizada para a obtenção dos resultados da pesquisa, abordando a coleta de dados e a forma como foram utilizados. Além disso, detalha os processos envolvidos no desenvolvimento da simulação proposta neste trabalho.

#### 3.1 Ferramenta de Otimização

O desenvolvimento da ferramenta de otimização foi fundamentado principalmente em Francisco (2018), que realiza sua simulação utilizando um algoritmo genético e uma tarifa trinomial, sem incluir geração distribuída, além de simular um sistema de pequeno porte. Com base nesse modelo, utilizando a plataforma do MATLAB, este trabalho reproduzirá a simulação com dois métodos de inteligência artificial, adotará uma tarifa binomial e incorporará a geração distribuída associada a um sistema de armazenamento de energia.

A ferramenta desenvolvida apresenta algumas características relevantes que merecem destaque.

- Opera com diferentes dados de entrada, adaptando os resultados às necessidades do usuário;
- Reduz os custos de energia;
- Exibe graficamente como os parâmetros elétricos estão se comportando;
- Otimiza a vida útil da bateria.

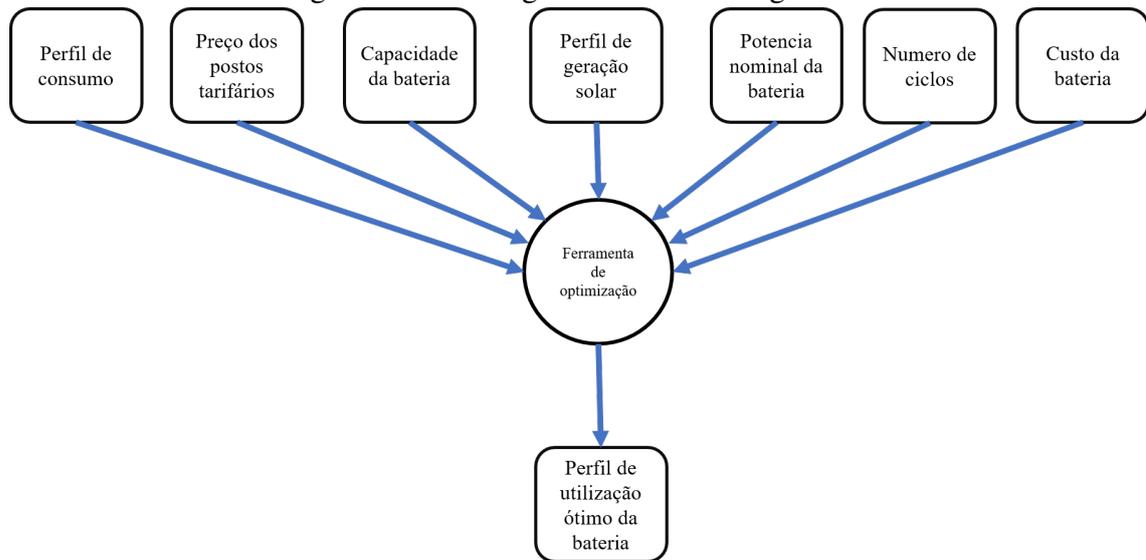
De maneira geral a figura 17, ilustra como a metodologia é estruturada de forma geral.

Nas seções seguintes, serão detalhadas as particularidades de cada parâmetro de entrada e sua importância para o funcionamento da simulação, além das especificidades da própria ferramenta de otimização.

##### 3.1.1 Origem dos dados de entrada

Antes de falar propriamente sobre os parâmetros de entrada, é importante esclarecer a origem dos dados que serão utilizados. Em relação ao consumo da unidade consumidora, os dados foram retirados do memorial de massa fornecido pela concessionária de energia. Além disso, informações como a tarifa de energia e os parâmetros elétricos da bateria foram obtidas a partir da proposta de Energia Solar com Armazenamento em Baterias na UFERSA, com o intuito de simular condições semelhantes às de uma proposta real de BESS.

Figura 17 – Fluxograma da metodologia



Fonte: Aatoria Própria

### 3.1.2 Perfil de consumo

O perfil de consumo refere-se aos dados de energia consumida ao longo do período considerado pela simulação. Neste trabalho, o período de simulação é de 24 horas, ou seja, cada dia é simulado individualmente. Para simplificar o tratamento dos dados, a análise foi realizada com base em um dia típico de cada mês. Um dia típico corresponde a um dia em que a universidade opera normalmente naquele mês; para meses letivos, seleciona-se um dia típico de aulas, e, para meses de férias, um dia representativo do período de recesso. Os perfis de consumo dos dias selecionados estão disponíveis para visualização no Anexo A.

A importância dos dados de consumo reside no cálculo do custo da energia, que depende diretamente da quantidade consumida pela rede elétrica, constituindo uma parte fundamental da análise.

### 3.1.3 Preço dos postos tarifários

Os preços dos postos tarifários referem-se às tarifas aplicadas à energia consumida em determinados períodos do dia. No Brasil, para consumidores classificados no Grupo A, que é o grupo aplicado ao estudo de caso deste trabalho, as tarifas de consumo de energia são obrigatoriamente binomiais, o que significa que há duas faixas de preços distintas, dependendo do horário. Assim, durante os horários de ponta, o custo da energia é mais elevado, enquanto nos períodos fora de ponta, o valor é reduzido. Esse modelo tarifário visa incentivar a redistribuição

do consumo ao longo do dia, reduzindo os picos de demanda na rede elétrica. No Rio Grande do Norte, a concessionária de energia estabeleceu os horários tarifários da seguinte maneira: horário de ponta, entre 17h30 e 20h30 nos dias úteis, e fora de ponta nos demais horários. Para simplificar a programação, considerou-se o horário de ponta entre 17h e 20h.

#### 3.1.4 Capacidade da bateria

A capacidade de uma bateria está diretamente relacionada à quantidade de energia que ela pode armazenar, sendo um parâmetro importante para o dimensionamento e uso adequado de sistemas de armazenamento de energia. Durante a simulação, é necessário garantir que o perfil de utilização projetado seja compatível com os limites de carga da bateria, evitando condições de operação que sejam impossíveis. Por exemplo, a bateria não deve descarregar além de seu estado de carga atual, tampouco deve ultrapassar a capacidade máxima de armazenamento definida. A capacidade de armazenamento definida para essa simulação é de 1.856 kWh.

#### 3.1.5 Perfil de geração solar

O perfil de geração solar refere-se à quantidade de energia que a usina fotovoltaica da unidade consumidora consegue gerar. Esse é um parâmetro importante, pois a energia utilizada para elevar o estado de carga da bateria é proveniente da geração distribuída. Dessa forma, o controle do estado de carga só é possível com base nessas informações. Para estimar a geração diária de energia solar da UFERSA, é necessário usar um método baseado na equação 3, o método da insolação, em que a equação será adaptada para funcionar em horas do dia. Assim, partindo da equação 3, para fazer a adaptação, é necessário inicialmente analisar as unidades presentes nos termos, obtendo, assim, a equação 4.

$$Wh/dia = (Wh/m^2/dia)(m^2)(\%) \quad (4)$$

sabendo que a unidade *dia* é igual a 24 horas, divide-se ambos os lados da equação por *h/dia*. Dessa forma tem-se a equação 5:

$$W = (W/m^2)(m^2)(\%) \quad (5)$$

Portanto, a equação para determinar potencia gerada em um horário específico é descrito

na equação 6:

$$P = AG\eta \quad (6)$$

Onde:

- $P$  energia produzida no horário especificado [ $W$ ].
- $G$  é a insolação no horário especificado [ $W/m^2$ ].
- $A$  é a área da superfície do módulo [ $m^2$ ].
- $\eta$  é a eficiência do módulo [%].

Vale ressaltar que, para calcular a energia produzida pela usina como um todo, é necessário multiplicar o resultado da equação 6 pela quantidade de placas existentes na usina. Dado o desafio de determinar a quantidade e os modelos específicos das placas nas usinas da UFERSA, foi realizado um levantamento da potência total de geração esperada no Campus Leste da UFERSA, que corresponde à soma da potência atualmente instalada de 973,69 kWp com a potência da usina proposta para instalação junto ao BESS, que é de 369 kWp, totalizando 1342,69 kWp. Utilizando como referência uma placa de 340 W, especificamente o modelo EMSJ 340P, cujas demais especificações técnicas encontram-se no Anexo B, chega-se ao número aproximado de 3949 placas. Embora existam atualmente placas de maior potência individual, optou-se por uma placa de menor potência para conferir mais precisão à simulação. Com o número de placas determinado, essa informação é utilizada na equação 6.

Os valores de insolação foram obtidos por meio do *software* Radiasol 2, considerando uma inclinação de 15° para Mossoró, tendo em vista sua latitude de aproximadamente 5°, mais 10°. Além disso, considerou-se que os painéis estão voltados para o norte. Por fim, no Anexo C, é possível visualizar o perfil de geração solar esperado para cada mês do ano.

### 3.1.6 Potência nominal da bateria

A potência nominal é o valor de potência ao qual um equipamento foi projetado para operar de maneira segura, estável e eficiente. Em outras palavras, é o limite máximo de entrada de energia que o equipamento pode suportar sem comprometer sua integridade e desempenho. Esse parâmetro é relevante para a análise, pois define a carga máxima que a bateria é capaz de sustentar durante o funcionamento. A operação acima da potência nominal pode resultar em sobrecarga, comprometendo a vida útil da bateria e aumentando os riscos de falhas.

Para baterias e sistemas de armazenamento de energia, a potência nominal também afeta a taxa de descarga, já que uma potência elevada acelera o consumo da energia armazenada, impactando a duração e a eficiência do sistema. Assim, escolher um valor adequado de potência nominal é necessário para assegurar a durabilidade e a confiabilidade do sistema energético. Para esta simulação, foi adotado um valor de potência nominal de 1000 kW, o que representa o limite seguro de operação para o sistema de armazenamento em estudo.

### 3.1.7 Número de ciclos

O número de ciclos representa a quantidade de vezes que a bateria pode passar por processos completos de carga e descarga, mantendo a eficiência e o desempenho dentro de padrões aceitáveis para a operação. Esse parâmetro é relevante para avaliar a durabilidade da bateria, pois, com o passar dos ciclos, o desgaste natural compromete sua capacidade de armazenar e liberar energia de forma eficaz. À medida que o número de ciclos aumenta, o desempenho da bateria tende a deteriorar, afetando sua vida útil e aumentando a necessidade de substituições. Isso implica em custos adicionais que devem ser levados em conta na análise de viabilidade econômica do sistema. Para esta simulação, será considerado um total de 3000 ciclos, o que representa a vida útil estimada da bateria antes de sua substituição ser necessária para manter a eficiência do sistema.

### 3.1.8 Custo da bateria

Assim como o número de ciclos, os custos relacionados à bateria também influenciam seu desgaste e o custo final de operação. Ao término da vida útil, determinada pela quantidade de ciclos suportados, é necessário substituir o banco de baterias completamente, o que gera um custo significativo. Esse fator deve ser considerado na análise, pois impacta tanto a viabilidade econômica quanto a longevidade do sistema energético. Para esta simulação foi considerado um banco avaliado em R\$1.500.000,00 baseado em preços médios de mercado em 2024.

## 3.2 Função de Aptidão

A função de aptidão tem como propósito verificar os custos resultantes de cada candidato (indivíduo) para avaliar quão apto ele é para ser a solução do problema proposto. Basicamente, o candidato é um vetor de 24 posições, com uma posição para cada hora do dia, que representa

uma forma de utilizar a bateria. Os valores positivos indicam a carga da bateria, enquanto os valores negativos representam a descarga. A função de custo está representada pelas equações 7 e 8.

$$Custo = \begin{cases} \sum_{n=1}^{24} E(n)(P_C(n) - Sobra) + D(P_B), & \text{se } P_B \geq 0 \\ \sum_{n=1}^{24} E(n)(P_C(n) + P_B(n) - Sobra) + D(P_B), & \text{se } P_B < 0 \end{cases} \quad (7)$$

$$D = \sum_{n=1}^{24} (Preco_{bateria}/Ciclos) Ciclos_{Realizados}(P_B) \quad (8)$$

O custo total é resultado da soma do custo com energia elétrica com o desgaste da bateria. Como é visto na equação 7, tem-se um somatório de 1 até 24 indicando que cada posição do vetor correspondente ao indivíduo será analisado separadamente.

- $E(n)$  é a função que descreve o preço da energia para cada hora do dia;
- $P_C(n)$  é a função que descreve o perfil de consumo da unidade consumidora sem SAE. É importante ressaltar que, nesta simulação, foram considerados tanto o perfil de consumo atual mais o perfil de geração atual. Essa abordagem foi adotada porque, no memorial de massa, o perfil de consumo já reflete a energia solar que foi abatida do total consumido;
- $P_B(n)$  é a função que descreve o perfil de injeção de energia na rede por parte da bateria, é o termo que o Algoritmo vai controlar e também os candidatos a soluções do problema. Um ponto importante a considerar neste trabalho é a utilização de energia solar para carregar o banco de baterias. Nesse contexto, a potência de carga das baterias será influenciada pelo perfil de geração distribuída, enquanto sua descarga estará limitada à potência nominal, de tal forma que  $P_B$  só ser utilizada na equação caso o valor presente na posição  $n$  do vetor seja negativo indicando a descarga da bateria. Caso o valor na posição  $n$  seja positivo, o valor será utilizado para atualizar o estado de carga da bateria.;
- $Preco_{bateria}$  é o valor constante gasto no banco de baterias;
- $Ciclos$  é o valor determinado pelo fabricante da bateria indicando quantos ciclos a bateria pode realizar.
- $Ciclos_{Realizados}$  é a quantidade de ciclos que a bateria realizou
- $Sobra$  é quantidade de energia solar não injetada na bateria no tempo  $n$ , que será injetado diretamente na rede de distribuição.

### 3.3 Implementação

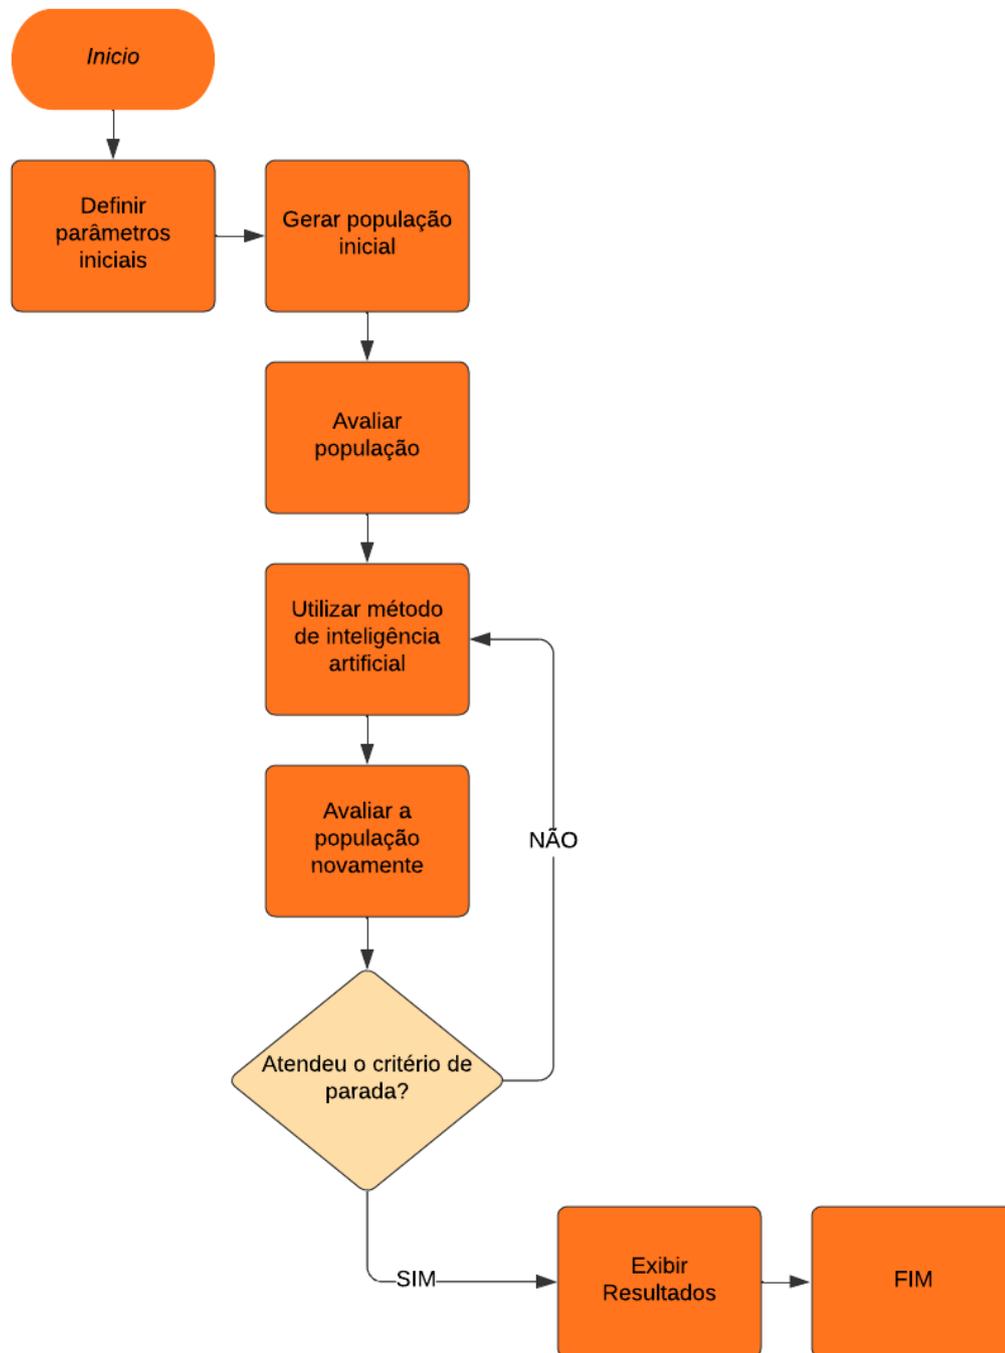
Nesta seção, será descrito o processo de implementação dos métodos propostos para a obtenção dos resultados. De forma concisa, cada etapa do desenvolvimento do código será apresentada em um fluxograma, ilustrando o passo a passo do processo, com o objetivo de tornar o entendimento mais claro.

#### 3.3.1 Algoritmo da ferramenta de otimização

O fluxograma para a implementação da ferramenta de otimização é apresentado na Figura 18. A seguir, cada bloco do fluxograma será detalhado individualmente.

1. Inicialmente, é necessário definir todos os parâmetros mencionados na metodologia. Onde, deve-se configurar um vetor de 24 posições para representar o perfil de consumo, o preço dos postos tarifários, o perfil de geração solar, além dos valores de potência nominal, capacidade da bateria, número de ciclos e o custo do banco de baterias.
2. A população inicial é definida por uma matriz com 24 colunas, e a quantidade de linhas é determinada pela quantidade de indivíduos escolhida para a simulação. As colunas representam as horas do dia, enquanto as linhas correspondem a cada indivíduo gerado. Vale ressaltar, que embora os valores gerados sejam aleatórios, esses possuem algumas restrições.
  - Cada elemento só pode assumir valores entre o limite inferior, definido pela potência nominal negativa, e o limite superior, correspondente à energia solar disponível, respeitando tanto a energia solar gerada quanto a potência de operação da bateria.
  - Os valores contidos em cada vetor não podem exceder o limite de descarga da bateria, nem ultrapassar seu limite máximo de carga.
3. Em seguida, os indivíduos devem passar pela função de avaliação para que sua aptidão seja testada. Assim, obtemos uma nova matriz, agora com uma coluna adicional que corresponde ao valor de aptidão de cada indivíduo gerado.
4. Nessa etapa, os indivíduos passam pelos operadores correspondentes ao método utilizado. Ou seja, neste ponto do código, aplicam-se os operadores do algoritmo genético ou os da evolução diferencial, seguindo a ordem específica de cada abordagem.
5. Em seguida, a nova população é reavaliada para verificar as aptidões atualizadas.
6. O programa deve avaliar se o critério de parada foi atendido para que os resultados sejam

Figura 18 – Fluxograma da ferramenta de otimização



Fonte: Autoria Própria

exibidos. Para este código, foram utilizados dois critérios, dos quais apenas um precisa ser satisfeito para que o algoritmo prossiga. O primeiro critério é o erro absoluto, calculado pela diferença absoluta entre a aptidão do melhor indivíduo e a aptidão média da população. O segundo critério refere-se à quantidade de iterações, ou seja, ao número de vezes que

os operadores foram utilizados. Enquanto nenhum dos critérios for atingido, as iterações continuarão.

7. Por fim, o programa deve retornar os seguintes resultados: Gráfico dos parâmetros elétricos, gráfico do comportamento do erro, economia calculada e tempo de simulação.

Como observação, a economia é calculada da seguinte forma: multiplica-se a curva de consumo pelas tarifas e, em seguida, a curva de consumo após o uso do sistema pelas mesmas tarifas. A diferença entre esses valores resulta na economia obtida.

É relevante ressaltar os parâmetros específicos de cada método utilizado. No caso da evolução diferencial, foi considerada uma taxa de cruzamento de 0,8 e um fator  $F$  igual a 0,8. Para o algoritmo genético, a taxa de cruzamento foi definida como 0,4, juntamente com uma taxa de mutação de 0,82. Além disso, para ambos os métodos, foram estabelecidos um limite de 500 iterações, um erro tolerado de  $1 \times 10^{-6}$  e um tamanho de população de 100 indivíduos.

Outro detalhe importante a ser destacado é como os operadores funcionam em um algoritmo genético. No caso do cruzamento, a posição de corte do gene é escolhida de forma aleatória, garantindo que a combinação dos pais gere descendentes diversificados. Já na mutação, o gene que sofrerá alteração também é selecionado aleatoriamente, introduzindo variações genéticas que podem explorar novas regiões do espaço de busca. Por fim, na seleção por roleta, um indivíduo é escolhido probabilisticamente para ser um dos pais no operador de cruzamento, com chances proporcionais ao seu valor de aptidão (fitness). Essa abordagem favorece indivíduos mais aptos, mas ainda permite que indivíduos menos aptos participem do processo, mantendo a diversidade da população.

Para concluir a metodologia, é necessário esclarecer que a presente simulação não leva em conta a parcela que envolve a demanda contratada da unidade consumidora, mas apenas o consumo de energia.

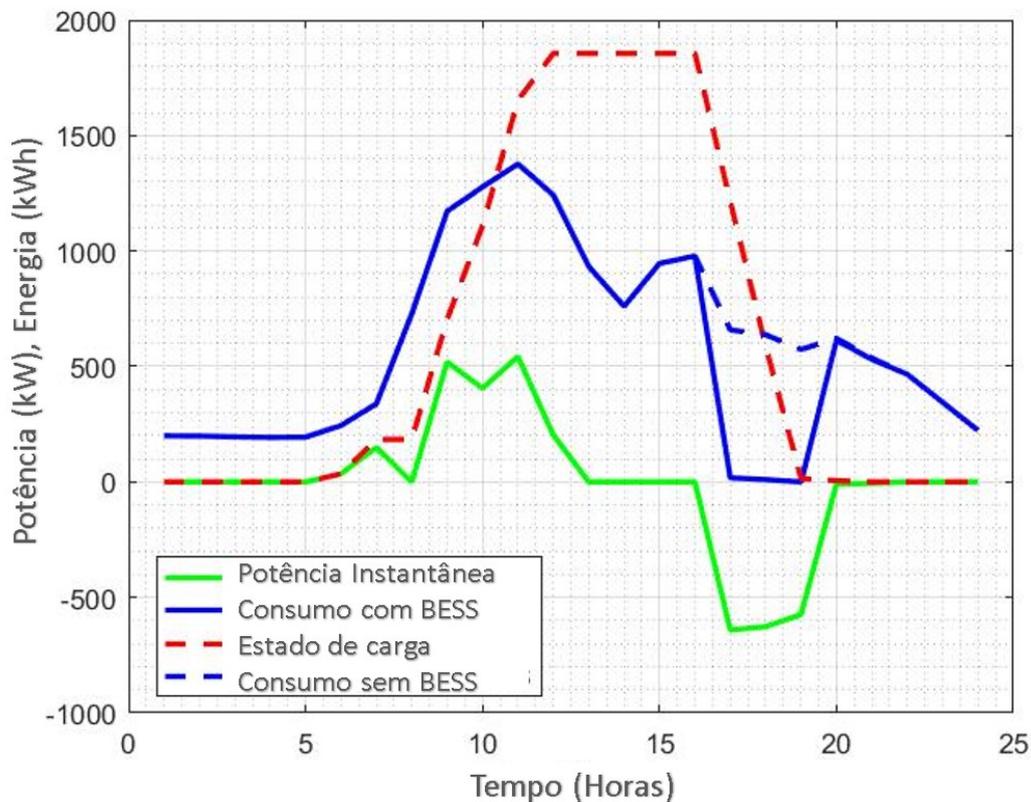
## 4 ANÁLISE DOS RESULTADOS

Neste capítulo, serão apresentados os resultados das simulações, utilizando como dados de entrada as informações de consumo da UFERSA no ano de 2023. Inicialmente, os resultados de cada método proposto serão analisados individualmente. Em seguida, será realizada uma análise comparativa dos resultados, a fim de avaliar qual método apresentou o melhor desempenho. Além de apresentar os resultados, também serão feitos comentários e análises a respeito dos dados obtidos.

### 4.1 Comportamento dos parâmetros elétricos

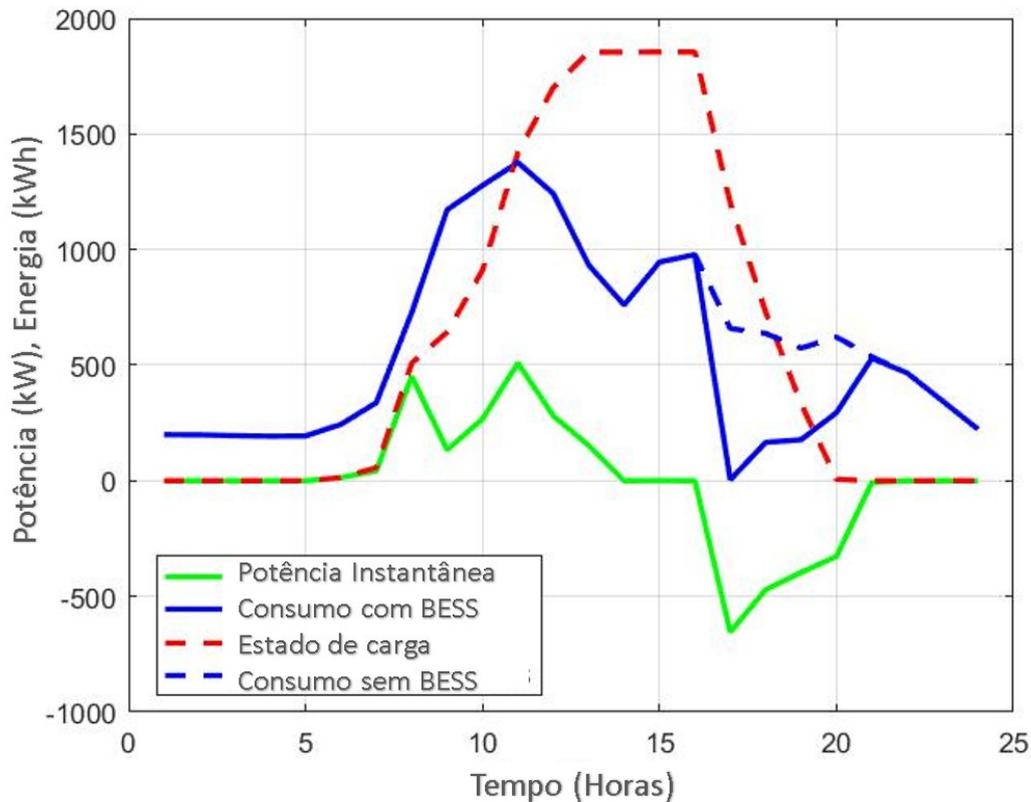
Com base na metodologia apresentada, é possível observar o efeito da ferramenta de otimização sobre os parâmetros elétricos em todos os dias selecionados. A título de exemplo, as Figuras 19 e 20 ilustra o efeito observado em um dia típico de janeiro utilizando algoritmo genético e evolução diferencial respectivamente.

Figura 19 – Efeito do algoritmo genético em um dia típico de janeiro



Fonte: Autoria Própria

Figura 20 – Efeito do evolução diferencial em um dia tipico de janeiro



Fonte: Autoria Própria

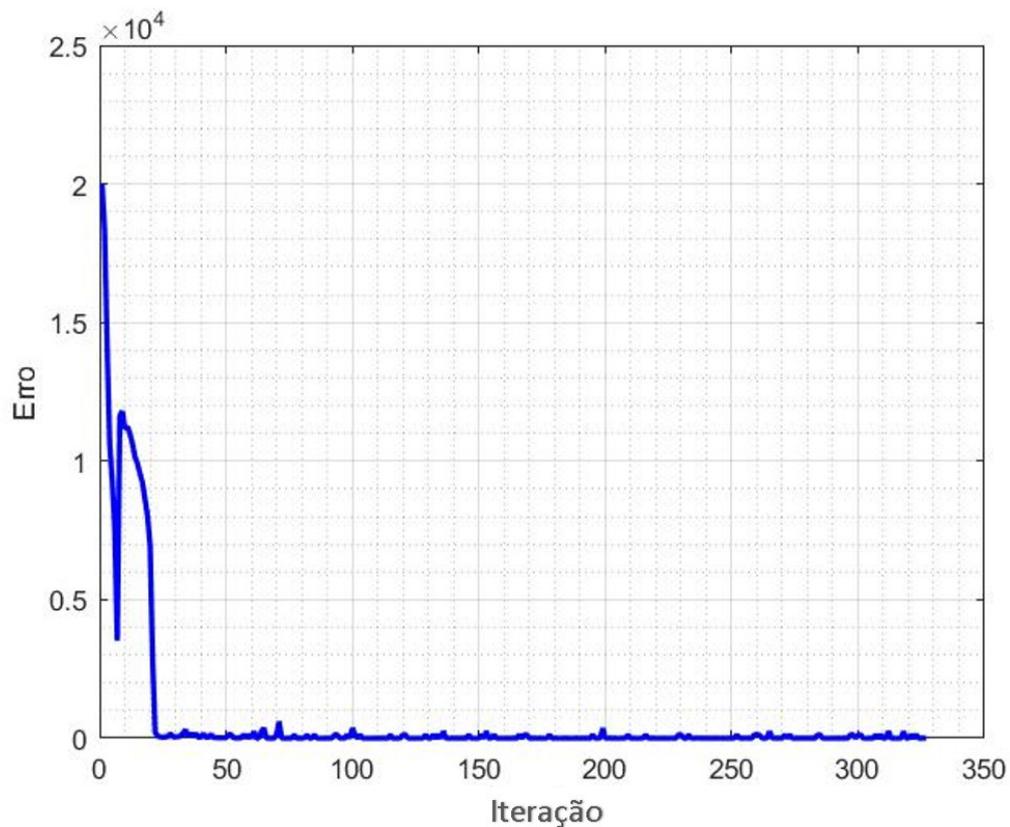
Com base nas figuras 19 e 20 e nos demais gráficos do Anexo D, é possível observar algumas características em comum.

- A bateria realiza apenas um ciclo de carga e descarga, indicando que o algoritmo conseguiu minimizar o custo associado ao desgaste da bateria. Esse comportamento também é evidenciado pela potência instantânea da bateria, que cruza o eixo das abscissas apenas uma vez, passando de valores positivos para negativos.
- Outro ponto a ser observado é que a ferramenta de otimização realiza uma descarga mais acentuada da bateria precisamente no período em que a energia tem maior custo. Isso demonstra que o algoritmo identificou que, nesse intervalo, é mais vantajoso injetar a carga da bateria na rede.
- O banco de baterias inicia descarregado e termina descarregado.

## 4.2 Comportamento da convergência através do erro

Para analisar a convergência do algoritmo, especialmente em relação ao número de iterações necessárias, as Figuras 21 e 22 ilustram o comportamento do erro ao longo das iterações para um dia típico de janeiro, aplicando-se, respectivamente, o algoritmo genético e o de evolução diferencial.

Figura 21 – Comportamento do erro do algoritmo genético num dia típico de janeiro

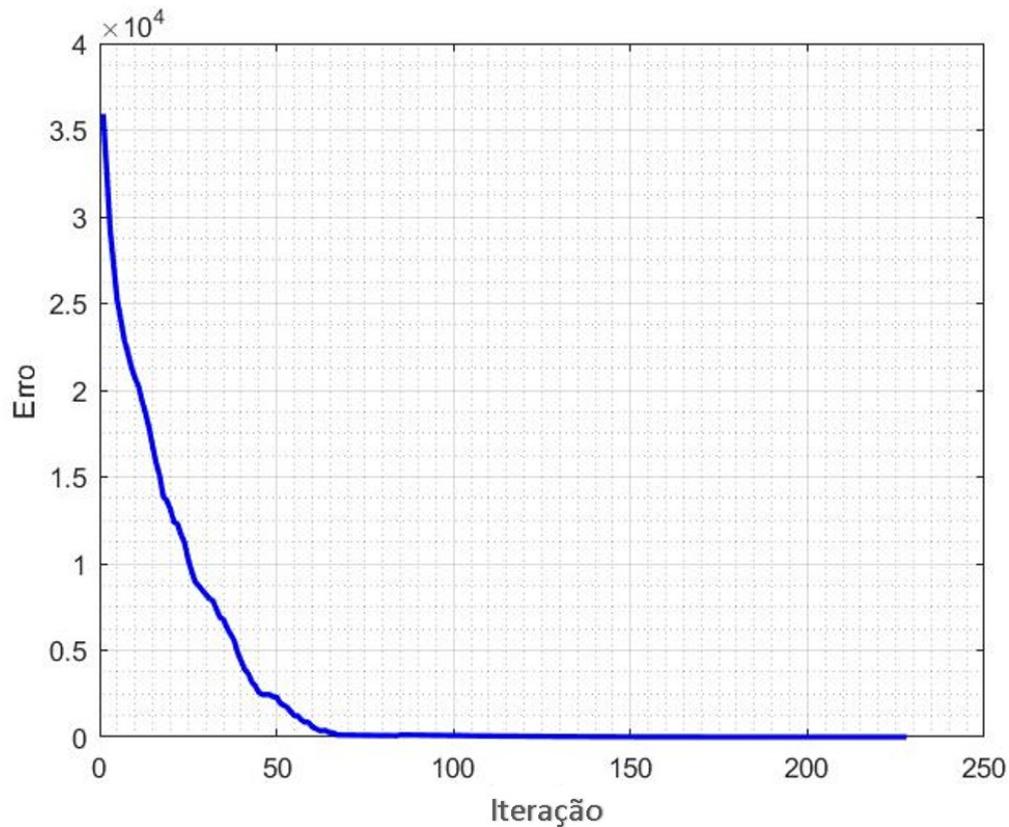


Fonte: Autoria Própria

Ao analisar as Figuras 21 e 22 juntamente com os gráficos do Anexo E, é possível fazer algumas observações importantes.

- No algoritmo genético, todas as simulações atingiram a convergência antes do limite de iterações estabelecido.
- No evolução diferencial a maioria das simulações não alcançaram o erro estabelecido, onde sua parada ocorreu somente ao fim das iterações. Houve exceções como as Figuras 22, 86 e 92.
- No evolução diferencial houve uma redução mais suave da curva do erro.

Figura 22 – Comportamento do erro do evolução diferencial num dia típico de janeiro



Fonte: Autoria Própria

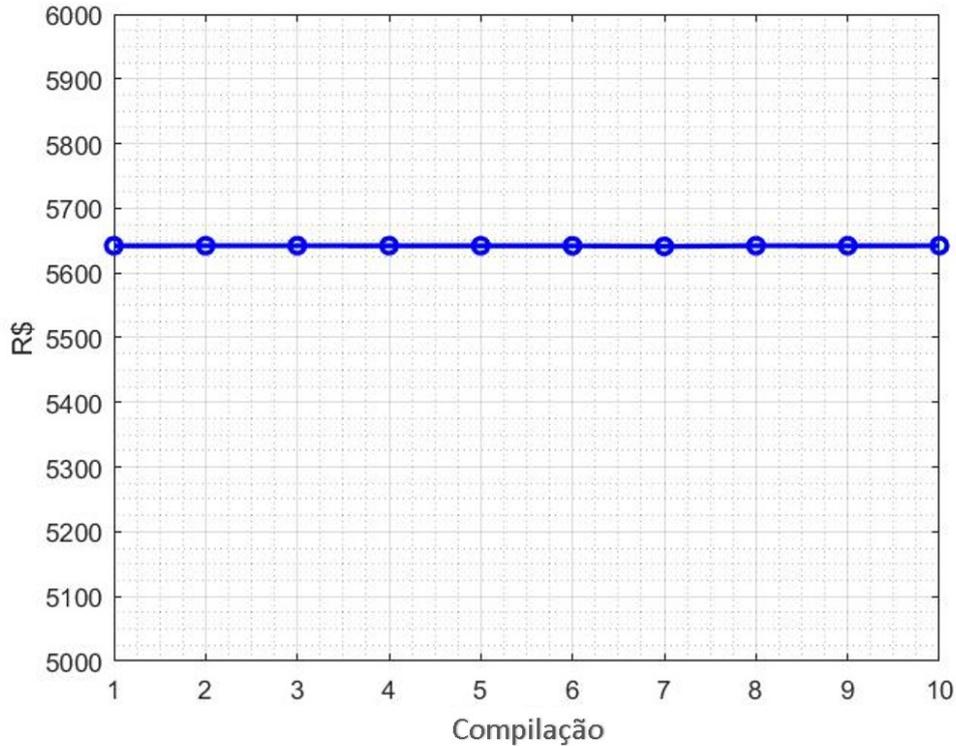
### 4.3 Análise da consistência do resultado

Por meio de 10 compilações sucessivas, buscou-se observar se o programa sempre retorna valores semelhantes ao convergir os resultados de economia. Essa análise permite avaliar a consistência dos resultados e a eficácia do algoritmo, possibilitando algumas conclusões. Como exemplo, seguem as Figuras 23 e 24, que representam, respectivamente, as 10 compilações para o mês de janeiro dos algoritmos genético e de evolução diferencial.

- O algoritmo genético retorna de modo resultados consistentes em todas compilações, com exceção das Figura 100, 104, 105.
- No evolução diferencial também retorna valores consistentes, com exceção das Figuras 112, 116, 117.
- No evolução diferencial houve uma redução mais suave da curva do erro.

Com o objetivo de analisar mais detalhadamente as inconsistências observadas nas simulações de alguns meses, foi calculado o desvio padrão de todas as simulações, a fim de quantificar a variação entre os valores obtidos. Os resultados são apresentados na Figura 25

Figura 23 – Consistência do algoritmo genético para o mês de janeiro

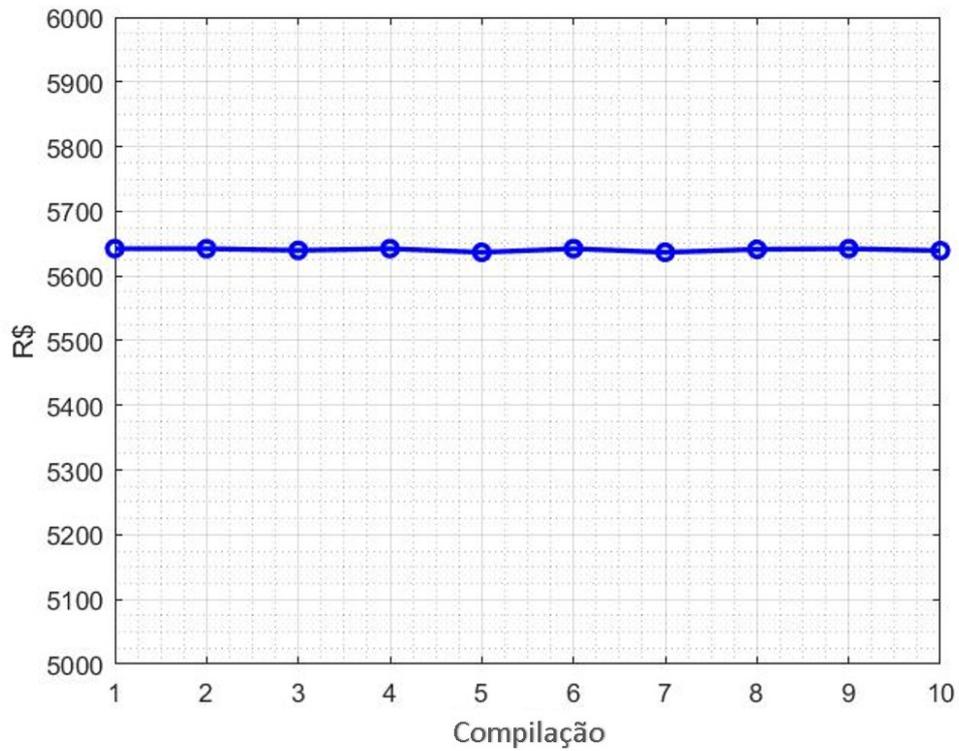


Fonte: Autoria Própria

Observa-se que as três maiores diferenças mencionadas anteriormente para cada algoritmo correspondem aos dias simulados em que o perfil de consumo apresenta variações mais acentuadas em relação aos demais. Como o perfil de consumo muda, há, conseqüentemente, uma alteração significativa nos dados de entrada, o que exige o ajuste dos parâmetros de controle de ambos os métodos em cada mês para reduzir o desvio padrão. No caso do algoritmo genético, esses parâmetros incluem a taxa de mutação e a taxa de cruzamento, enquanto para o algoritmo de evolução diferencial, são ajustados a taxa de cruzamento e a constante  $F$ .

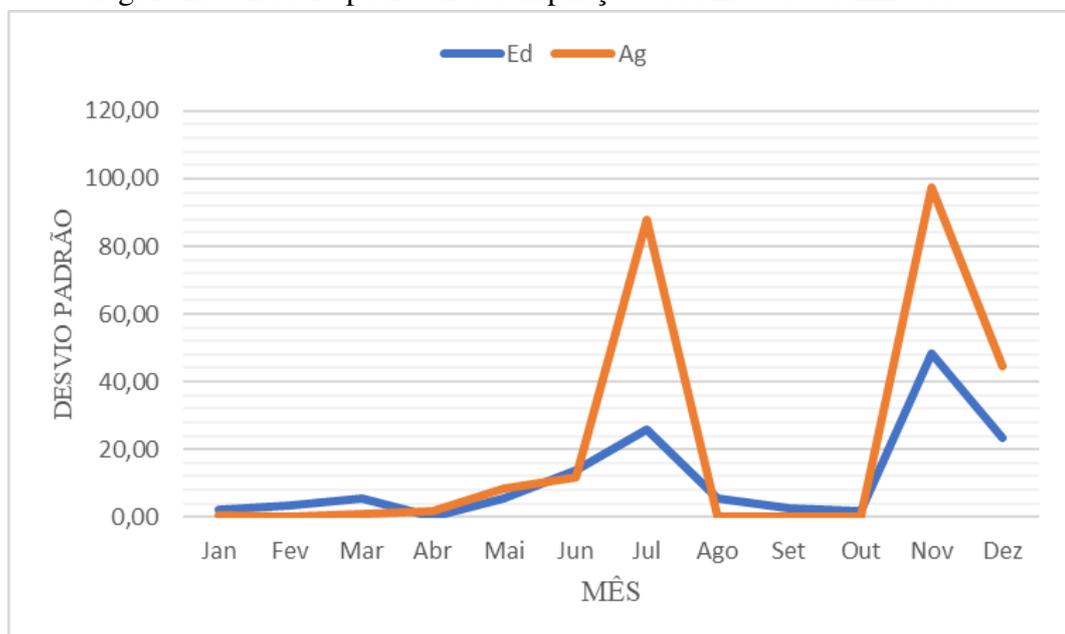
Observa-se também que o método de evolução diferencial apresentou menores valores de desvio padrão, mesmo nos dias com maiores variações de consumo, mantendo os mesmos ajustes nos parâmetros de controle. Além disso, foi comparado se ambos os métodos convergem para resultados semelhantes considerando a última compilação realizada. Os resultados dessa comparação estão apresentados na Figura 26.

Figura 24 – Consistência do evolução diferencial para o mês de janeiro



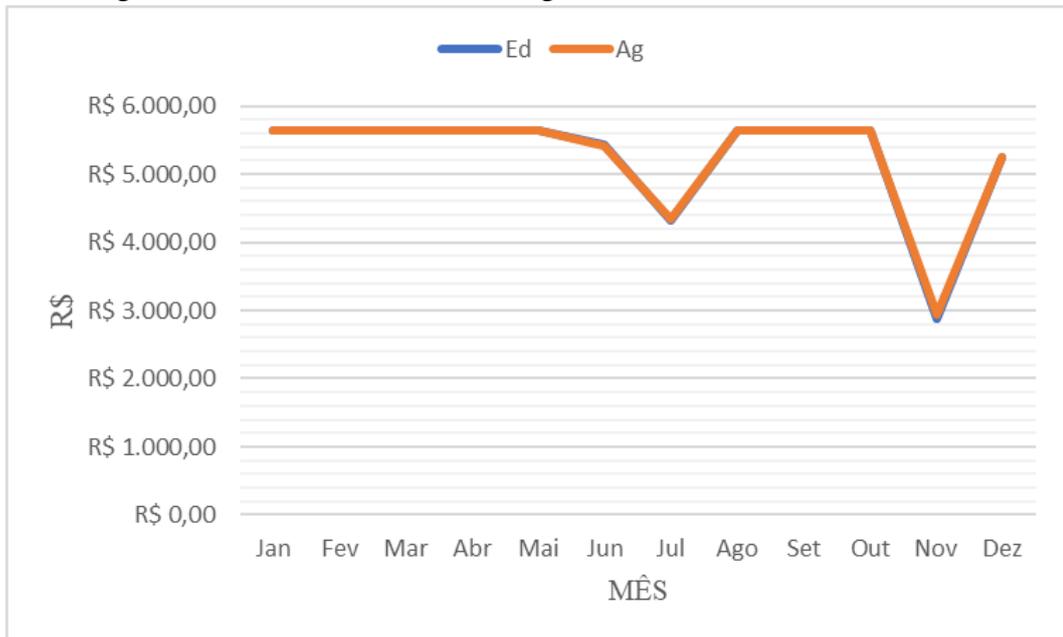
Fonte: Autoria Própria

Figura 25 – Desvio padrão nas compilações dos métodos utilizados



Fonte: Autoria Própria

Figura 26 – Similaridade de convergência de ambos os métodos



Fonte: Autoria Própria

#### 4.4 Análise do resultado financeiro

Após obter os resultados das simulações, realizou-se uma análise financeira simplificada. Para isso, o valor obtido em cada dia típico foi multiplicado por 30, representando o total mensal estimado. Em seguida, todos os valores foram somados, resultando nos valores apresentados na Tabela 3. É importante ressaltar que, além de simplificar a análise, esta não considera o valor referente à demanda contratada nem outros encargos associados ao uso da rede elétrica da concessionária de energia.

#### 4.5 Tempo de simulação

Para determinar qual dos métodos é mais eficiente em relação ao tempo de convergência, foram medidos os tempos necessários para realizar as simulações descritas no Anexo F. Os resultados estão apresentados na Tabela 4.

Tabela 3 – Comparação de Custos Mensais entre os Métodos ED e AG

	<b>ED</b>	<b>AG</b>
Jan	R\$ 5.639,20	R\$ 5.642,20
Fev	R\$ 5.642,20	R\$ 5.642,20
Mar	R\$ 5.636,20	R\$ 5.641,20
Abr	R\$ 5.642,20	R\$ 5.642,00
Mai	R\$ 5.639,20	R\$ 5.641,10
Jun	R\$ 5.440,70	R\$ 5.415,90
Jul	R\$ 4.326,10	R\$ 4.350,50
Ago	R\$ 5.642,20	R\$ 5.642,20
Set	R\$ 5.634,40	R\$ 5.641,30
Out	R\$ 5.642,20	R\$ 5.642,20
Nov	R\$ 2.871,90	R\$ 2.928,30
Dez	R\$ 5.251,60	R\$ 5.239,10
Economia:	R\$ 1.890.243,00	R\$ 1.892.046,00

Fonte: Autoria Própria

Tabela 4 – Tempo de simulação das 10 compilações

	ED (Segundos)	AG (Segundos)
Jan	36,7	46,6
Fev	45,3	24,9
Mar	46,4	19,8
Abr	23,5	16,3
Mai	45,2	19,1
Jun	49,5	22,5
Jul	55,9	24,8
Ago	48,3	17,9
Set	53,1	14,2
Out	32,5	29,9
Nov	72,1	20,8
Dez	59,5	22,6
Média	47,3	23,3

Fonte: Autoria Própria

## 5 CONCLUSÕES E TRABALHOS FUTUROS

Com base nos resultados obtidos em todas as simulações e na análise realizada sobre esses dados, é possível chegar a uma série de conclusões, além de identificar lacunas que podem ser abordadas em trabalhos futuros.

Inicialmente, em relação aos resultados referentes ao comportamento dos parâmetros elétricos, observa-se que estes se comportam de maneira coerente. O algoritmo é capaz de identificar o momento mais vantajoso para a injeção de energia através da bateria, correspondendo ao intervalo de tempo durante o horário de ponta. Além disso, a bateria realiza apenas um ciclo de carga e descarga, o que demonstra que o algoritmo também é eficiente em reduzir o desgaste da bateria em ambos os métodos.

Em relação ao comportamento da convergência, analisando a redução do erro, o algoritmo genético apresenta mais resultados em que a convergência é alcançada rapidamente pelo critério de erro, o que reduz o esforço computacional, tornando o método mais eficaz nesse aspecto. Por outro lado, o algoritmo de evolução diferencial exibe uma redução mais gradual do erro. No entanto, ao final, o algoritmo genético ainda se mostra mais eficaz na obtenção do valor desejado.

Em relação à consistência do programa, fica evidente que o algoritmo genético apresenta maior instabilidade quando comparado ao algoritmo de evolução diferencial ao longo das 10 compilações. Isso é confirmado pela observação de que o desvio padrão calculado é maior nos dias em que ocorrem maiores variações nos dados de entrada, indicando que o algoritmo genético requer ajustes mais precisos em seus parâmetros de controle. Apesar disso, ambos os métodos geraram resultados de simulação muito semelhantes, o que confirma que o programa está efetivamente encontrando os valores mínimos de custo de energia para o sistema.

Com base na análise financeira, ambos os métodos apresentaram resultados muito semelhantes. Diante dos resultados obtidos, não é possível concluir qual deles apresenta melhor desempenho nesse aspecto, uma vez que ambos se mostram igualmente eficientes.

A análise dos tempos de simulação revelou que o método do algoritmo genético apresentou, em média, uma velocidade de convergência aproximadamente duas vezes maior que a do método de evolução diferencial. Esse resultado evidencia uma maior eficiência do algoritmo genético e uma significativa redução no esforço computacional.

Por fim, o presente trabalho alcançou seu objetivo de simular o funcionamento do BESS no contexto de gestão de tarifas de consumo, gerando resultados de magnitude semelhante aos encontrados na proposta de energia solar com armazenamento em baterias na UFERSA. As

principais diferenças observadas podem ser atribuídas à análise financeira simplificada, além de não levar em consideração os gastos com a demanda de energia e os encargos relacionados à concessionária local. Além disso, ao comparar os dois métodos de inteligência artificial abordados, o algoritmo genético demonstrou melhor desempenho em termos de esforço computacional, enquanto o algoritmo de evolução diferencial apresentou maior estabilidade nos parâmetros de controle.

Para trabalhos futuros, podem ser identificados diversos pontos de melhoria e possibilidades de expansão deste estudo.

- Análise do problema com a inclusão da simulação do impacto da demanda contratada pelo cliente.
- Análise do problema considerando os possíveis encargos da concessionária de energia.
- Simulação do problema utilizando outros métodos de inteligência artificial, com destaque para técnicas de classificação alternativas.
- Estudo da influência dos parâmetros de controle no problema em questão, visando calibrá-los de forma mais eficiente.
- Realizar simulações considerando clientes com diferentes níveis de tensão.

## REFERÊNCIAS

- Adafruit Learning System. **Li-Ion and LiPoly Batteries**. 2024. Accessed: 2024-10-22. Disponível em: <<https://learn.adafruit.com/li-ion-and-lipoly-batteries/voltages>>.
- AKHIL, A. A.; HUFF, G.; CURRIER, A. B.; KAUN, B. C.; RASTLER, D.; CHEN, S. B.; COTTER, A.; BRADSHAW, D.; GAUNTLETT, W. Electricity storage handbook in collaboration with nreca. **Sandia National Laboratories**, p. 1–340, 2013.
- ALMEIDA, C.; KAGAN, N. Using genetic algorithms and fuzzy programming to monitor voltage sags and swells. **IEEE Intelligent Systems**, IEEE, v. 26, n. 2, p. 46–53, 2011.
- ANEEL. **Agência Nacional de Energia Elétrica**. 2022. 20/02/2024. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/tarifas/entenda-a-tarifa/postos-tarifarios>>.
- ASSUNÇÃO, P. M. M. **Despacho Ótimo em Sistemas Eléctricos de Energia Isolados**. Dissertação (Mestrado) — Instituto Politecnico do Porto (Portugal), 2010.
- BARBOUR, E. Energy storage sense. **Online**. URL: <http://energystoragesense.com/>. (latest accessed 31.07. 2018), 2018.
- BEAUDIN, M.; ZAREIPOUR, H.; SCHELLENBERGLABE, A.; ROSEHART, W. Energy storage for mitigating the variability of renewable electricity sources: An updated review. **Energy for sustainable development**, Elsevier, v. 14, n. 4, p. 302–314, 2010.
- BOLUND, B.; BERNHOFF, H.; LEIJON, M. Flywheel energy and power storage systems. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 11, n. 2, p. 235–258, 2007.
- BUENO, A.; BRANDAO, C. Visão geral de tecnologia e mercado para os sistemas de armazenamento de energia elétrica no brasil. **Associação Brasileira de Armazenamento e Qualidade de Energia**, v. 1, p. 1–62, 2016.
- CANALES, F. A.; BELUCO, A.; MENDES, C. A. B. Usinas hidrelétricas reversíveis no brasil e no mundo: aplicação e perspectivas. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental-REGET/UFSM, Santa Maria**, v. 19, n. 2, p. 1230–1249, 2015.
- CANTANE, D. A.; JUNIOR, O. H. A.; HAMERSCHMIDT, M. B. Tecnologias de armazenamento de energia aplicadas ao setor elétrico brasileiro. **Editora Scienza, São Carlos-SP, Brasil**, 2020.
- CARNEGIE, R.; GOTHAM, D.; NDERITU, D.; PRECKEL, P. Utility scale energy storage systems, state utility forecasting group. **Purdue University**, v. 1, 2013.
- CHEN, H.; CONG, T. N.; YANG, W.; TAN, C.; LI, Y.; DING, Y. Progress in electrical energy storage system: A critical review. **Progress in natural science**, Elsevier, v. 19, n. 3, p. 291–312, 2009.
- COSTA, Y. F.; BORTONI, S. E. C. Sistemas de armazenamento de energia elétrica em redes inteligentes: Características, oportunidades e barreiras. 2016.
- CROMPTON, T. R. **Battery reference book**. [S.l.]: Newnes, 2000.

- DAZA, E. F. B. **SISTEMAS DE ARMAZENAMENTO DE ENERGIA: Desafios Regulatórios e Econômicos para sua inserção em Sistemas de Potência**. [S.l.]: Simplíssimo, 2020.
- DÍAZ-GONZÁLEZ, F.; SUMPER, A.; GOMIS-BELLMUNT, O.; VILLAFÁFILA-ROBLES, R. A review of energy storage technologies for wind power applications. **Renewable and sustainable energy reviews**, Elsevier, v. 16, n. 4, p. 2154–2171, 2012.
- Energy Storage Sense. **Energy Storage Sense**. 2014. Acesso em 4 de fevereiro de 2019. Disponível em: <<http://energystoragesense.com/superconducting-magnetic-energy-storage-smes>>.
- ERBAO, C.; MINGYONG, L.; KAI, N. A differential evolution & genetic algorithm for vehicle routing problem with simultaneous delivery and pick-up and time windows. **IFAC Proceedings Volumes**, Elsevier, v. 41, n. 2, p. 10576–10581, 2008.
- FRANCISCO, R. J. S. **Sistema Inteligente de Gestão de Armazenamento de Energia**. Tese (Doutorado), 2018.
- GABAY, J. **Supercapacitor options for energy harvesting systems**. Digi-Key, 2013. Acesso em 4 de fevereiro de 2019. Disponível em: <<https://www.digikey.com/en/articles/techzone/2013/aug/supercapacitor-options-for-energy-harvesting-systems>>.
- GEN, M.; CHENG, R. **Genetic algorithms and engineering optimization**. [S.l.]: John Wiley & Sons, 1999. v. 7.
- GOLDBARG, E.; GOLDBARG, M.; LUNA, H. **Otimização combinatória e metaheurísticas: algoritmos e aplicações**. [S.l.]: Elsevier Brasil, 2017.
- GONZÁLEZ, A.; GOIKOLEA, E.; BARRENA, J. A.; MYSYK, R. Review on supercapacitors: Technologies and materials. **Renewable and sustainable energy reviews**, Elsevier, v. 58, p. 1189–1206, 2016.
- GOULART, V. V. *et al.* Projeto de um sistema de armazenamento de energia utilizando baterias de lítio de segunda vida descartadas de veículos elétricos nissan leaf. Florianópolis, SC, 2021.
- HU, X.; ZOU, C.; ZHANG, C.; LI, Y. Technological developments in batteries: a survey of principal roles, types, and management needs. **IEEE Power and Energy Magazine**, IEEE, v. 15, n. 5, p. 20–31, 2017.
- HUFF, G.; CURRIER, A. B.; KAUN, B. C.; RASTLER, D. M.; CHEN, S. B.; BRADSHAW, D. T.; GAUNTLETT, W. D. Doe/epr 2013 electricity storage handbook in collaboration with nreca. **Rep. Sand**, v. 340, 2013.
- KUMAR, N. Superconducting magnetic energy storage (smes) system. **Optimization in Power System; Woodhead Publishing Series in Energy: Sawston Cambridge, UK**, p. 1–4, 2015.
- LAMBORA, A.; GUPTA, K.; CHOPRA, K. Genetic algorithm-a literature review. In: **IEEE. 2019 international conference on machine learning, big data, cloud and parallel computing (COMITCon)**. [S.l.], 2019. p. 380–384.
- LOPES, I. L.; SANTOS, F. A. O.; PINHEIRO, C. A. M. **Inteligência Artificial**. São Paulo: Elsevier, 2014.

- LUKMAN, N.; IRFAN, M.; NUGRAHA, A.; JUMADI, J. Comparison between genetic algorithm with differential evolution in study scheduling. In: IOP PUBLISHING. **IOP Conference Series: Materials Science and Engineering**. [S.l.], 2021. v. 1098, n. 3, p. 032082.
- LUO, X.; WANG, J.; DOONER, M.; CLARKE, J. Overview of current development in electrical energy storage technologies and the application potential in power system operation. **Applied energy**, Elsevier, v. 137, p. 511–536, 2015.
- MANTHOPOULOS, A.; WANG, X. A review and comparison of lithium-ion battery soc estimation methods for electric vehicles. In: IEEE. **IECON 2020 the 46th annual conference of the IEEE industrial electronics society**. [S.l.], 2020. p. 2385–2392.
- MARIANO, J. D.; FREITAS, P. M. B. de; MEDEIROS, L. de; BLOCK, P. A. B.; RIBOLDI, V. B.; TUO, J.; JUNIOR, J. U. Pv-battery energy storage progress in brazil: a review. Preprints, 2021.
- MUELLER, J.; ROPP, M.; ATCITTY, S. Power conversion systems. In: **2020 US DOE Energy Storage Handbook**. [S.l.]: Sandia National Laboratories, 2020.
- NÉIA, S. S.; ARTERO, A. O.; CANTÃO, L. A. P.; CUNHA, C. B. da. Roteamento de veículos utilizando otimização por colônia de formigas e algoritmo genético. **Meta-heurísticas em pesquisa operacional. cap**, v. 14, p. 219–236, 2013.
- NIZAM, M.; MAGHFIROH, H.; ROSADI, R. A.; KUSUMAPUTRI, K. D. Design of battery management system (bms) for lithium iron phosphate (lfp) battery. In: IEEE. **2019 6th International Conference on Electric Vehicular Technology (ICEVT)**. [S.l.], 2019. p. 170–174.
- PEREIRA, T. L. S. **Participação da Produção Renovável no Mercado de Energia de Reserva de Regulação**. Tese (Doutorado) — Instituto Politecnico do Porto (Portugal), 2020.
- RANAWAT, D.; PRASAD, M. A review on electric vehicles with perspective of battery management system. In: IEEE. **2018 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECCOT)**. [S.l.], 2018. p. 1539–1544.
- RENEWABLE, I.; IRENA, I. R. *et al.* Electricity storage and renewables: Costs and markets to 2030. 2017.
- ROSÁRIO, R. R. L. d. *et al.* Algoritmos evolutivos adaptativos para problemas de programação de pessoal. 2012.
- SABIHUDDIN, S.; KIPRAKIS, A. E.; MUELLER, M. A numerical and graphical review of energy storage technologies. **Energies**, MDPI, v. 8, n. 1, p. 172–216, 2014.
- SHI, Y.; GAO, H.; WU, D. An improved differential evolution algorithm with novel mutation strategy. In: IEEE. **2014 IEEE Symposium on Differential Evolution (SDE)**. [S.l.], 2014. p. 1–8.
- SILVA, P. L. T. d. **Sistema de armazenamento de energia utilizando bateria com aplicação para suavização de potência**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2018.

SINGH, A.; KHAMPARIA, A. A hybrid whale optimization-differential evolution and genetic algorithm based approach to solve unit commitment scheduling problem: Wodega. **Sustainable computing: informatics and systems**, Elsevier, v. 28, p. 100442, 2020.

SOUZA, H. d. Armazenamento de energia num cenário de evolução das energias renováveis variáveis. **São Paulo, Unicamp**, p. 81, 2020.

STORN, R.; PRICE, K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. **Journal of global optimization**, Springer, v. 11, p. 341–359, 1997.

VANGARI, M.; PRYOR, T.; JIANG, L. Supercapacitors: review of materials and fabrication methods. **Journal of energy engineering**, American Society of Civil Engineers, v. 139, n. 2, p. 72–79, 2013.

VARDAKOS, S.; GUTIERREZ, M.; XIA, C. Parameter identification in numerical modeling of tunneling using the differential evolution genetic algorithm (dega). **Tunnelling and underground space technology**, Elsevier, v. 28, p. 109–123, 2012.

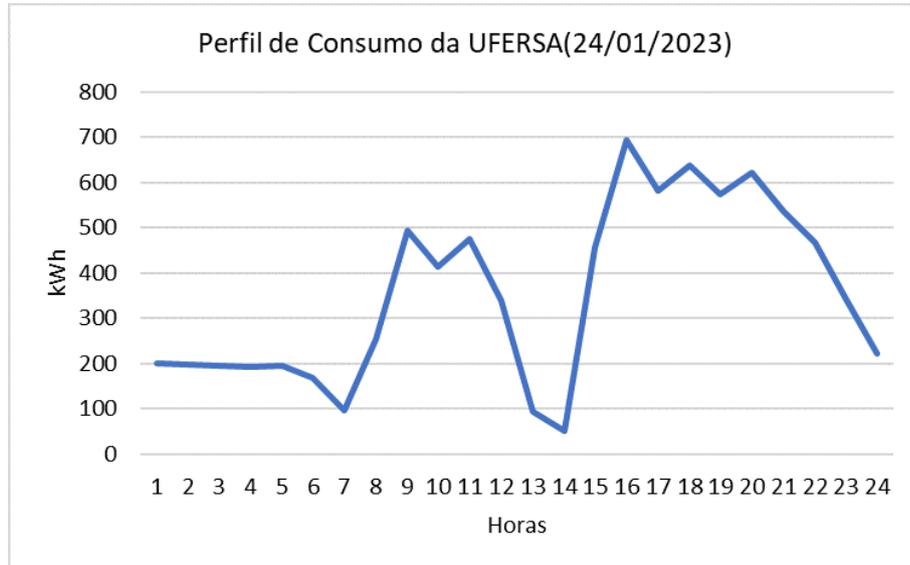
VIAN, Â.; TAHAN, C. M. V.; AGUILAR, G. J. R.; GOUVEA, M. R.; GEMIGNANI, M. M. F. **Armazenamento de Energia: Fundamentos Tecnologia e Aplicações**. [S.l.]: Editora Blucher, 2021.

VILLALVA, M. G. **Energia Solar Fotovoltaica? Conceitos e aplicações: guía del usuario**. [S.l.]: Saraiva Educação SA, 1983.

WAGO. **Controlador Lógico Programável**. 2021. Acesso em: 27 mar. 2021. Disponível em: <<https://www.wago.com/br/automacao-wago/controlador-logico-programavel>>.

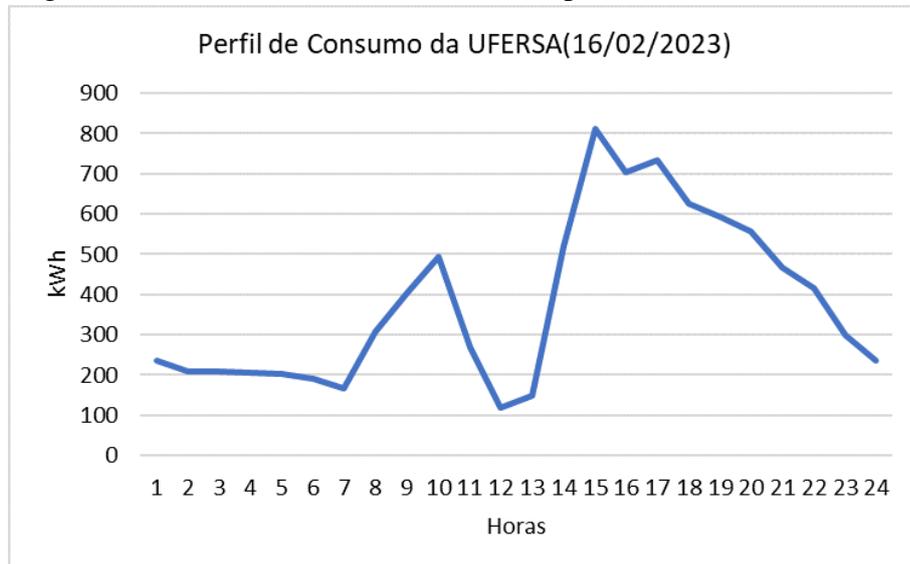
**ANEXO A – PERFIL DE CONSUMO**

Figura 27 – Perfil de consumo de um dia típico do mês de janeiro



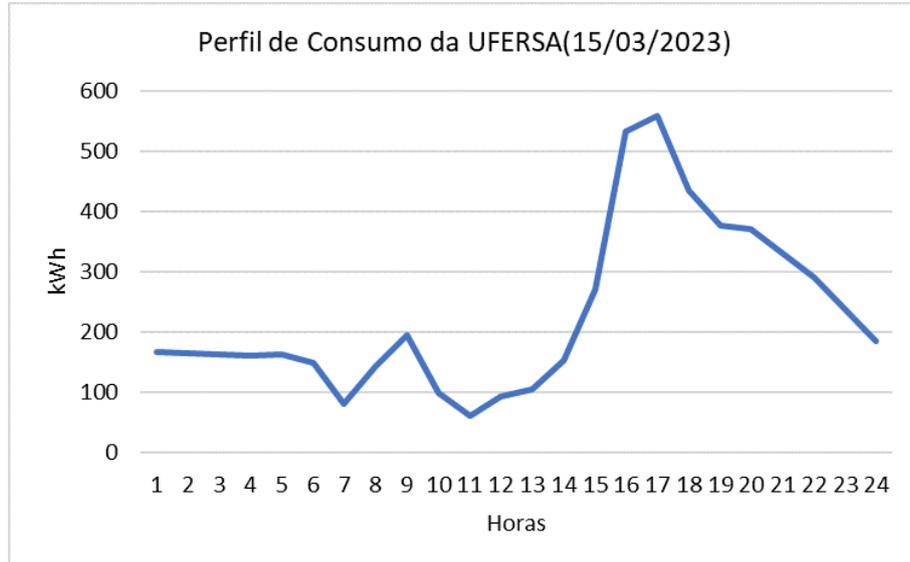
Fonte: Autoria Própria

Figura 28 – Perfil de consumo de um dia típico do mês de fevereiro



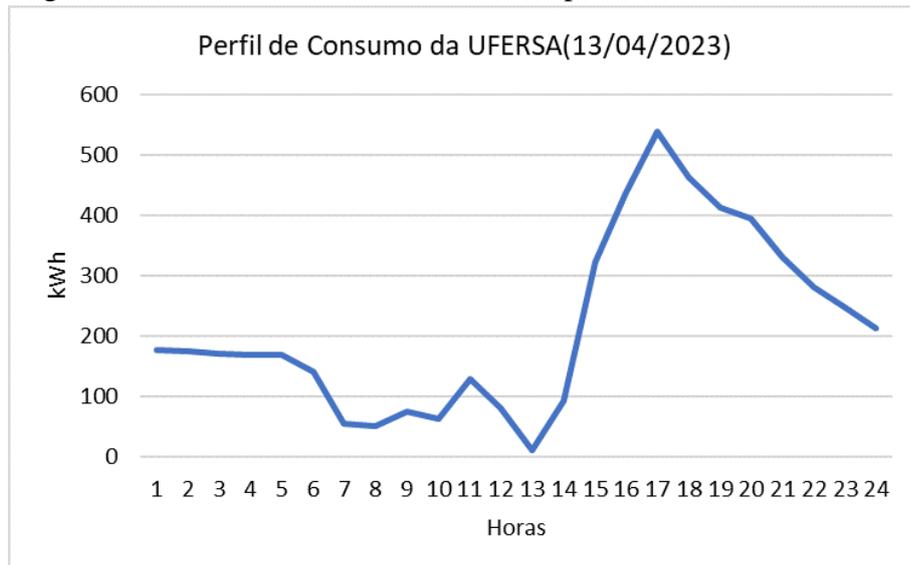
Fonte: Autoria Própria

Figura 29 – Perfil de consumo de um dia típico do mês de março



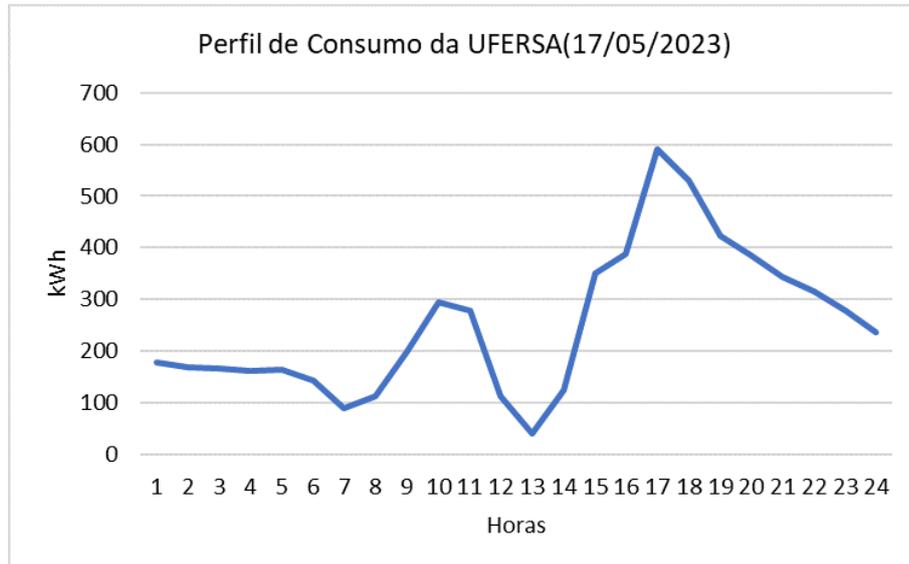
Fonte: Autoria Própria

Figura 30 – Perfil de consumo de um dia típico do mês de abril



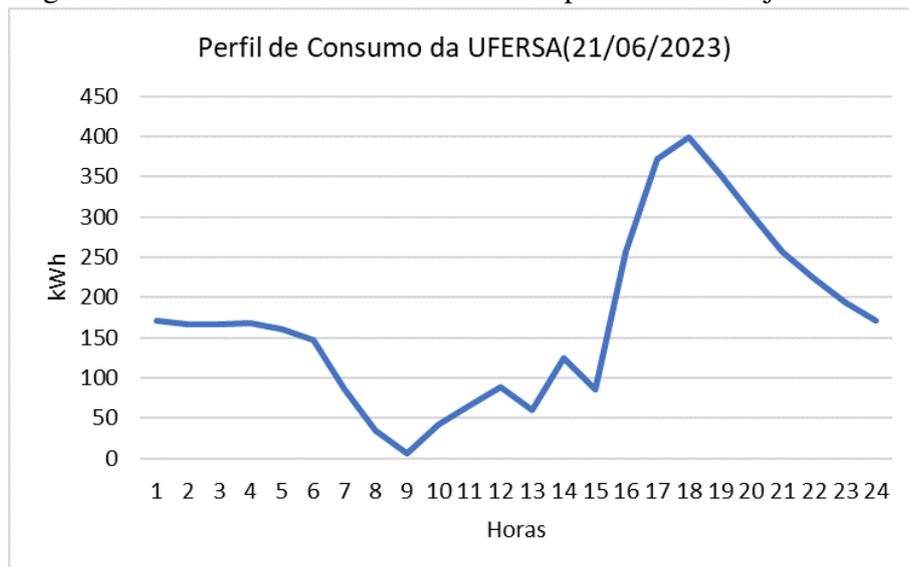
Fonte: Autoria Própria

Figura 31 – Perfil de consumo de um dia típico do mês de maio



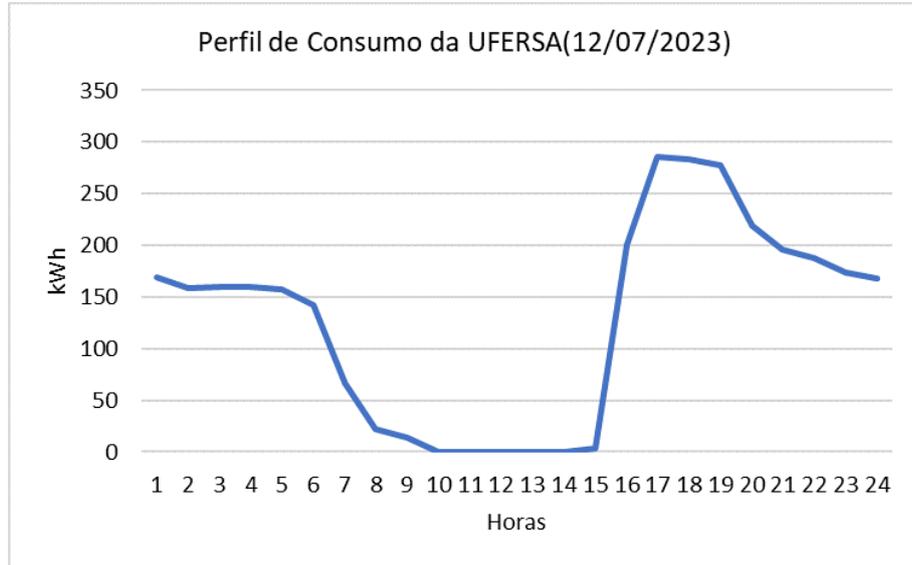
Fonte: Autoria Própria

Figura 32 – Perfil de consumo de um dia típico do mês de junho



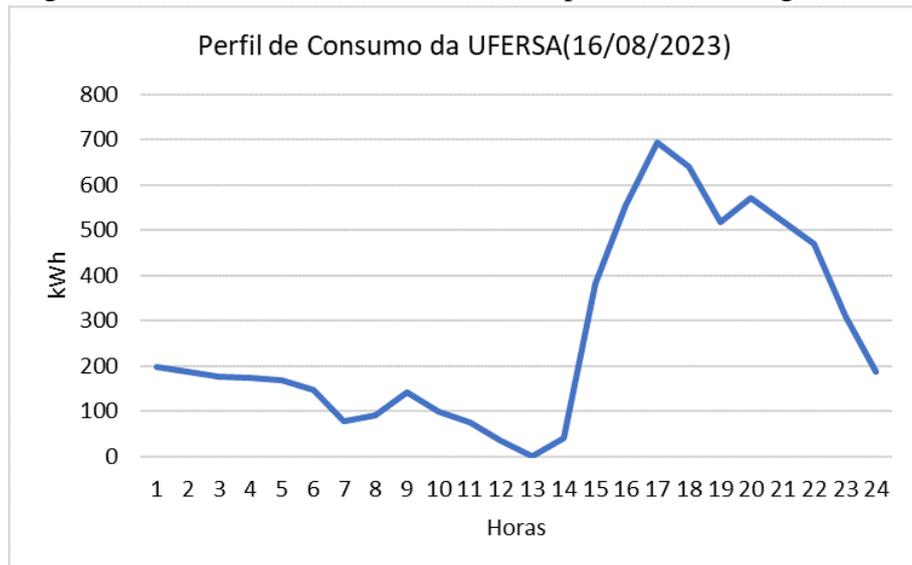
Fonte: Autoria Própria

Figura 33 – Perfil de consumo de um dia típico do mês de julho



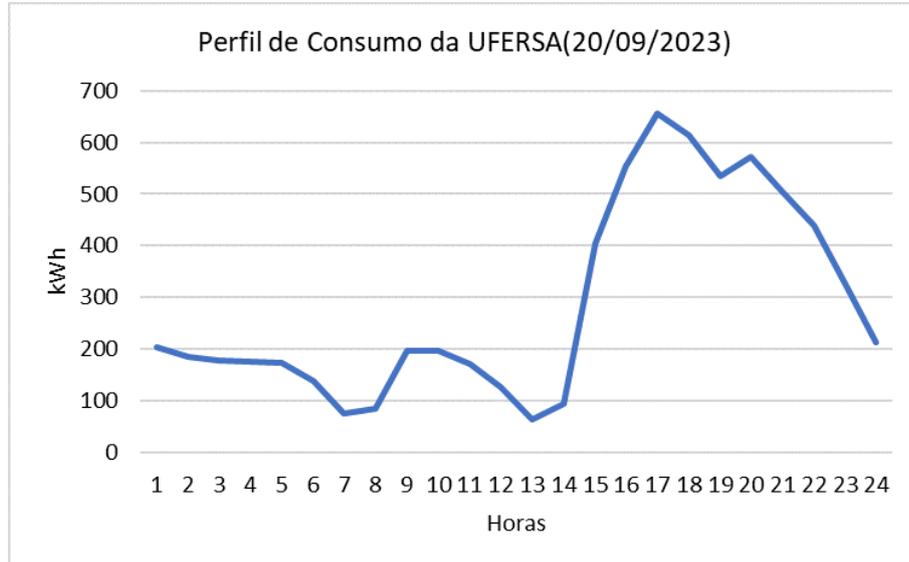
Fonte: Autoria Própria

Figura 34 – Perfil de consumo de um dia típico do mês de agosto



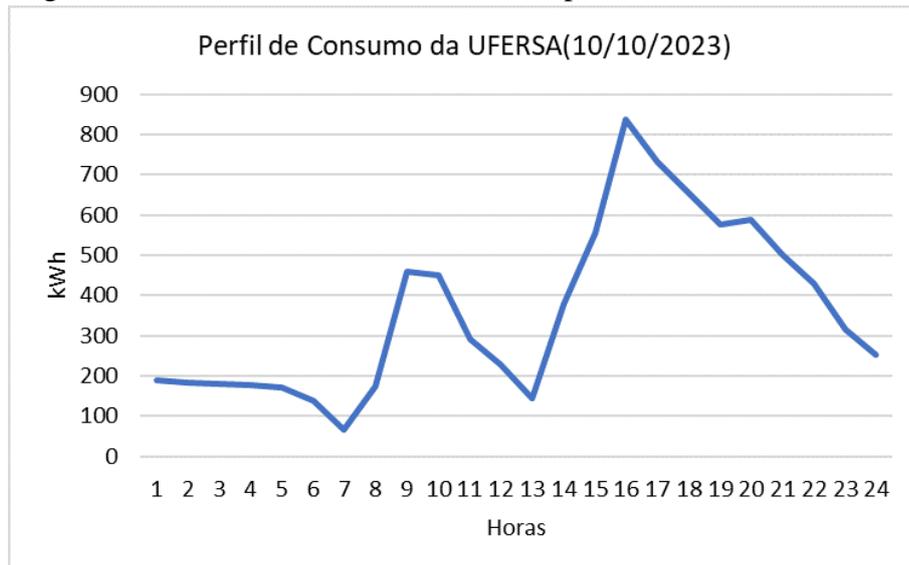
Fonte: Autoria Própria

Figura 35 – Perfil de consumo de um dia típico do mês de setembro



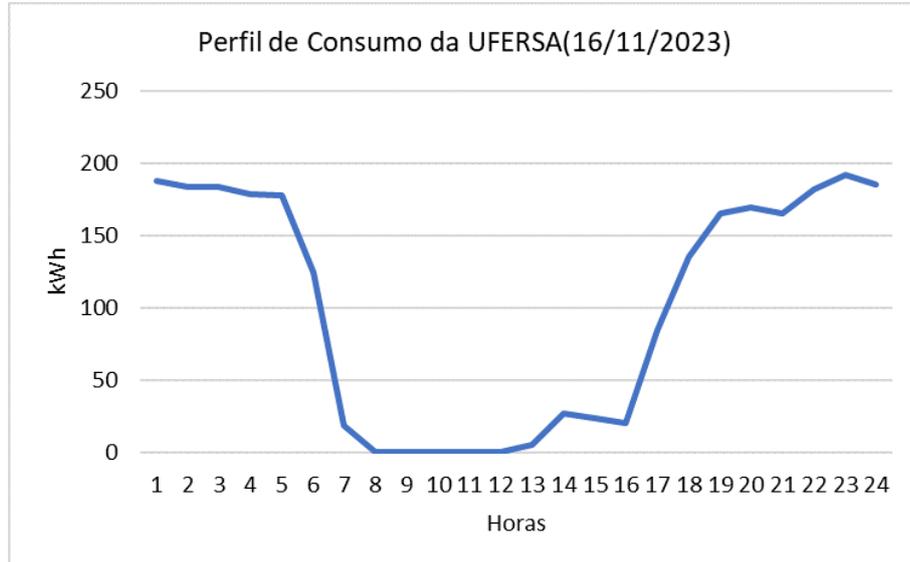
Fonte: Autoria Própria

Figura 36 – Perfil de consumo de um dia típico do mês de outubro



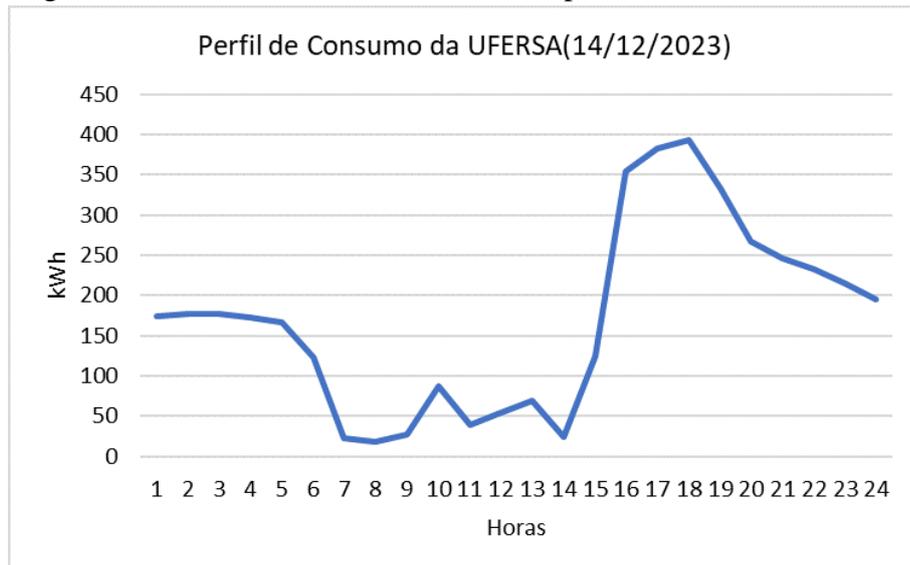
Fonte: Autoria Própria

Figura 37 – Perfil de consumo de um dia típico do mês de novembro



Fonte: Autoria Própria

Figura 38 – Perfil de consumo de um dia típico do mês de dezembro



Fonte: Autoria Própria

**ANEXO B – DATASHEET: EMSJ 340P**

## EMSJ 340P

### Módulo Fotovoltaico Policristalino 72 células 340 W



O módulo fotovoltaico policristalino oferece excelente custo-benefício na geração de energia solar, em projetos de todos os tamanhos. Mantendo o rigoroso padrão Intelbras de qualidade, todos os módulos são testados individualmente. Segurança e qualidade aliadas a 25 anos de garantia de desempenho (no mínimo 80% de seu desempenho nominal).

- » Fácil instalação
- » Excelente eficiência do módulo de até 17,2%
- » 5BB
- » Grau de proteção da caixa de junção: IP68
- » Alta eficiência e durabilidade
- » Rigoroso controle de qualidade

### Especificações técnicas

Modelo	EMSJ 340P
Registro INMETRO	Registro 000470/2021 (Portaria nº004/2011)
<b>PERFORMANCE EM STC*</b>	
Potência máxima	340 W (+5W)
Tensão máxima de operação	37,74 V <sub>cc</sub>
Corrente máxima de operação	9,01 A
Tensão de circuito aberto	46,37 V <sub>cc</sub>
Corrente de curto circuito	9,55 A
Eficiência do módulo	17,2 %
* Sob condições de teste (STC) de irradiação de 1000W/2m, espectro AM de 1,5 e temperatura de célula de 25°C.	
<b>PERFORMANCE EM NOCT*</b>	
Potência máxima	253 W

Tensão máxima de operação	35,11 Vcc
Corrente máxima de operação	7,21 A
Tensão de circuito aberto	43,49 Vcc
Corrente de curto circuito	7,70 A

\*Sob condições (NOTC) de irradiação de 800W/m<sup>2</sup>, espectro AM 1.5, temperatura ambiente de 20°C, velocidade do vento 1m/s.

## ESPECIFICAÇÕES MECÂNICAS

Tipo de célula	Policristalino
Dimensões do modulo (L x A x P)	996 x 1979 x 35 mm
Número de células	72
Peso	21,2 kg
Comprimento do cabo	1200 mm
Diodos Bypass	3
Seção transversal do cabo	4 mm <sup>2</sup>
Material da estrutura	Liga de alumínio anodizado
Grau de proteção (caixa de junção)	IP68

## CONDIÇÕES DE OPERAÇÃO

Temperatura de operação	-40°C - +85°C
Carga de neve	Até 5400 Pa
Carga de vento	Até 2400 Pa
Tensão máxima do Sistema	1500 Vcc
Corrente máxima do fusível	20 A
Conector	Compatível com MC4

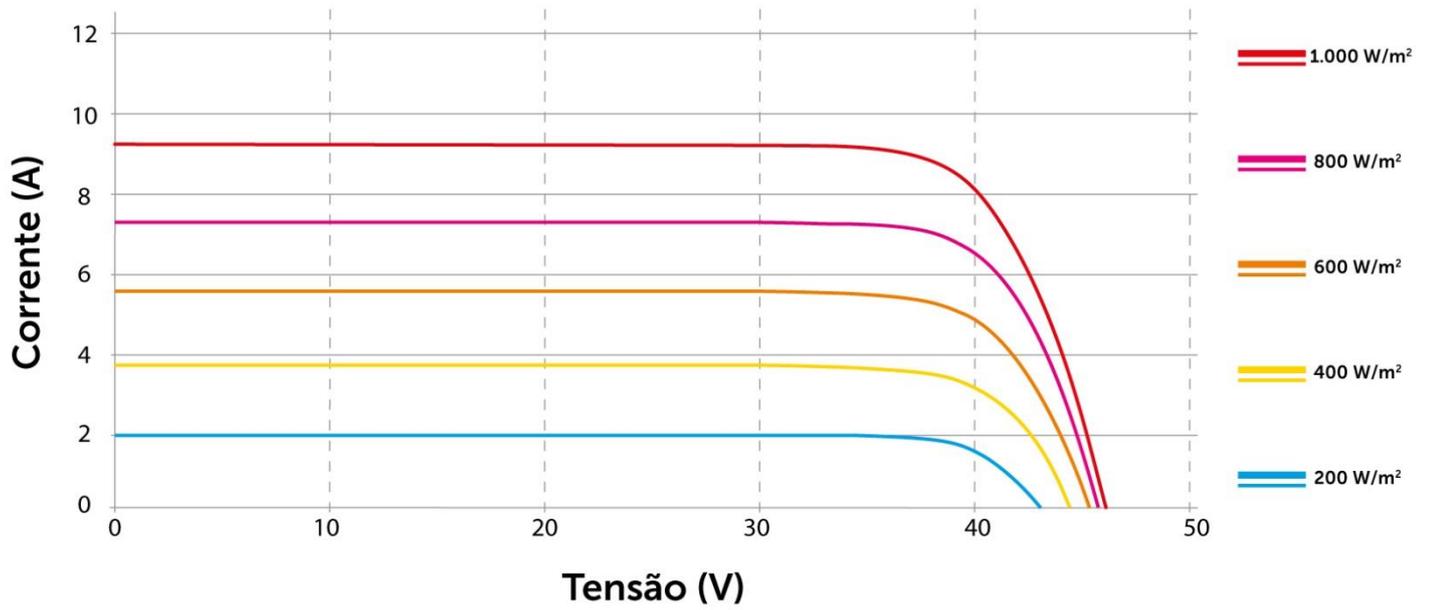
## CARACTERÍSTICAS DE TEMPERATURA

Coefficiente de temperatura máxima (Pmax)	-0,41%/°C
Coefficiente de temperatura (Voc)	-0,31%/°C
Coefficiente de temperatura (Isc)	+0,05 %/°C
Temperatura nominal da célula (NOCT)	45±2°C

## EMBALAGEM

Peças por caixa	31
Peças por Container de 40' HQ	726 peças

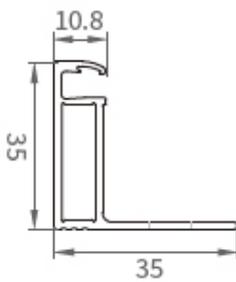
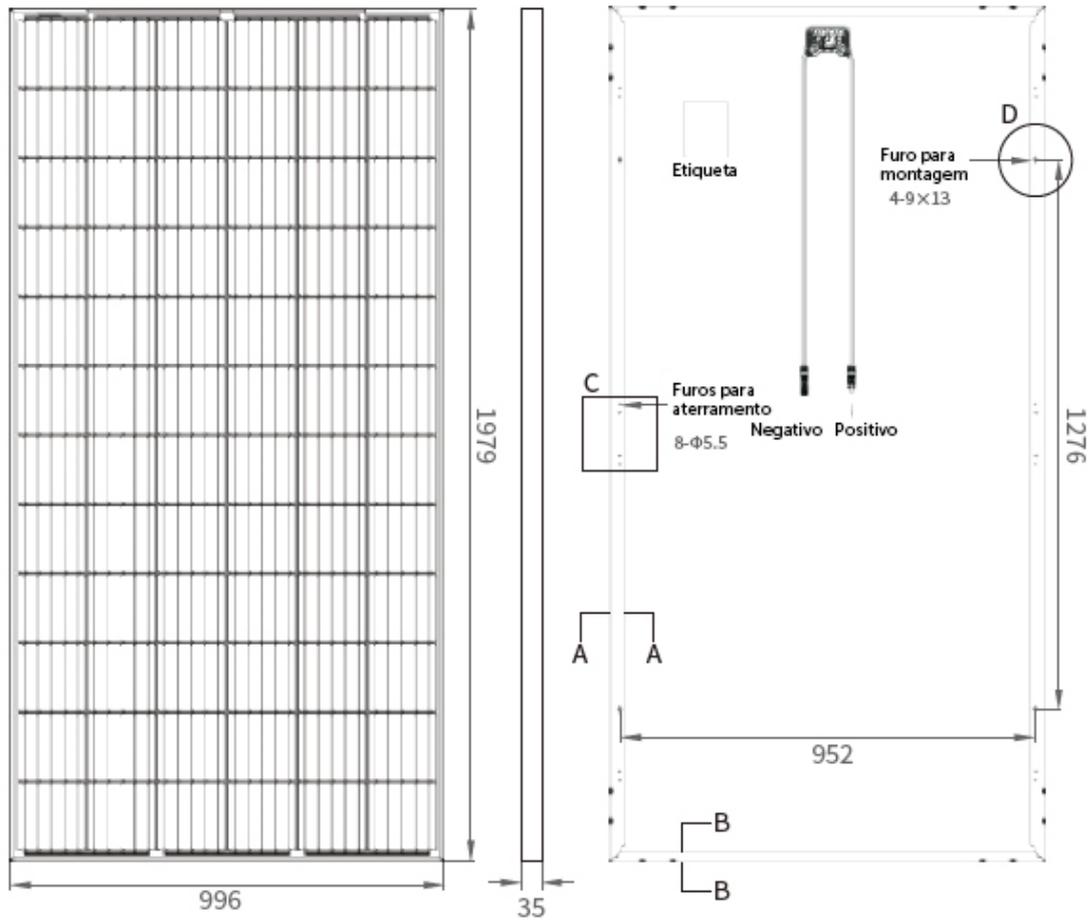
**CURVAS I x V**



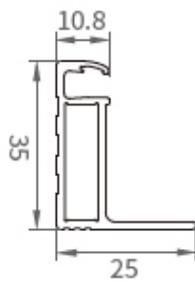
**25 anos de garantia de desempenho linear**



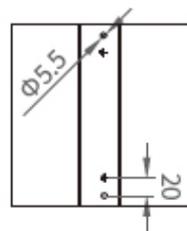
## Dimensões do módulo



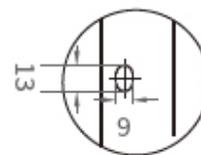
A-A



B-B



C



D

Fotos do produto



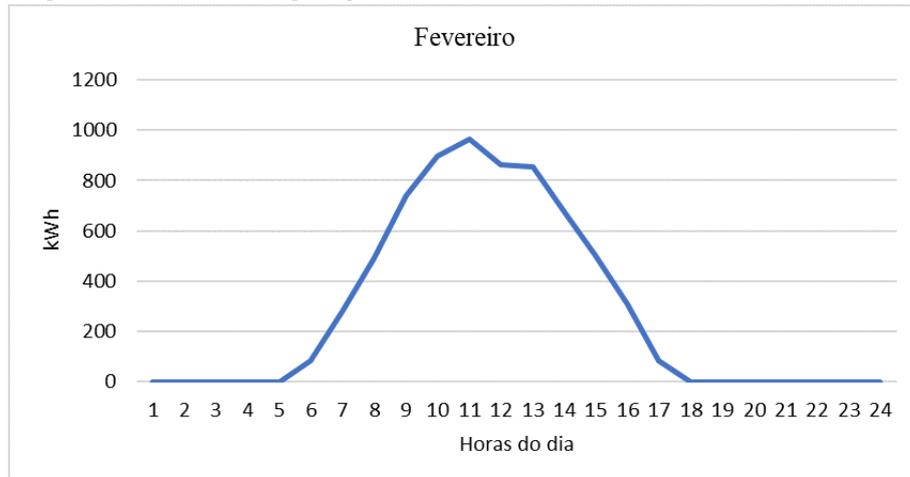
## ANEXO C – PERFIL DE GERAÇÃO SOLAR

Figura 39 – Perfil de geração em janeiro



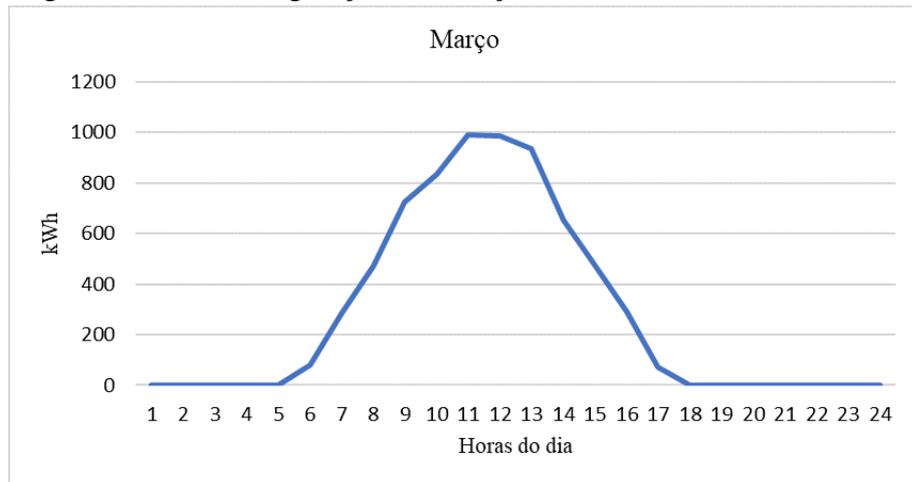
Fonte: Autoria Própria

Figura 40 – Perfil de geração em fevereiro



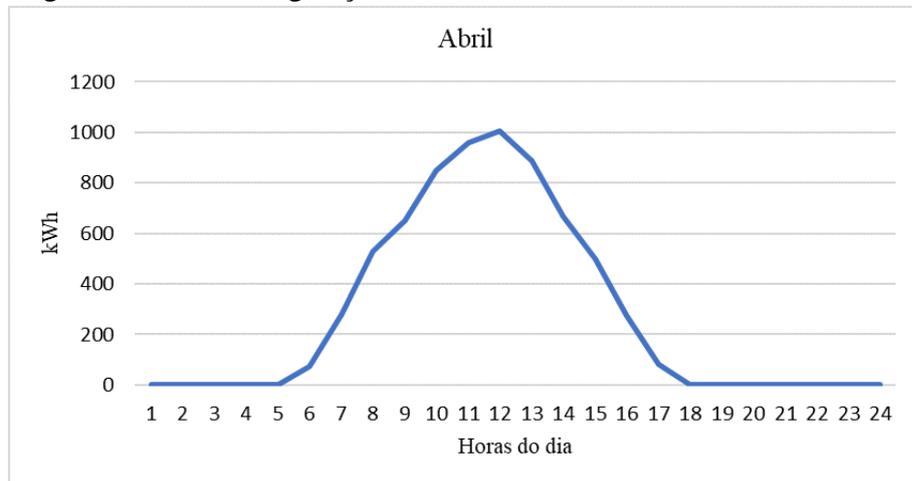
Fonte: Autoria Própria

Figura 41 – Perfil de geração em março



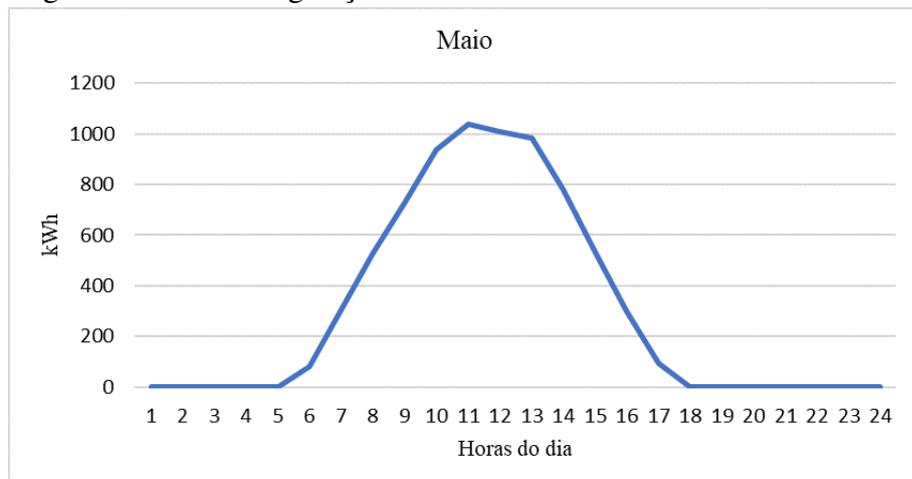
Fonte: Autoria Própria

Figura 42 – Perfil de geração em abril



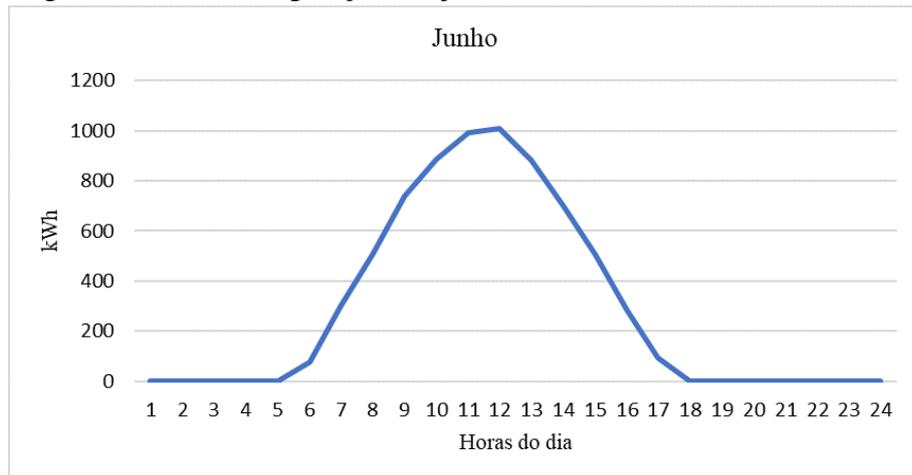
Fonte: Autoria Própria

Figura 43 – Perfil de geração em maio



Fonte: Autoria Própria

Figura 44 – Perfil de geração em junho



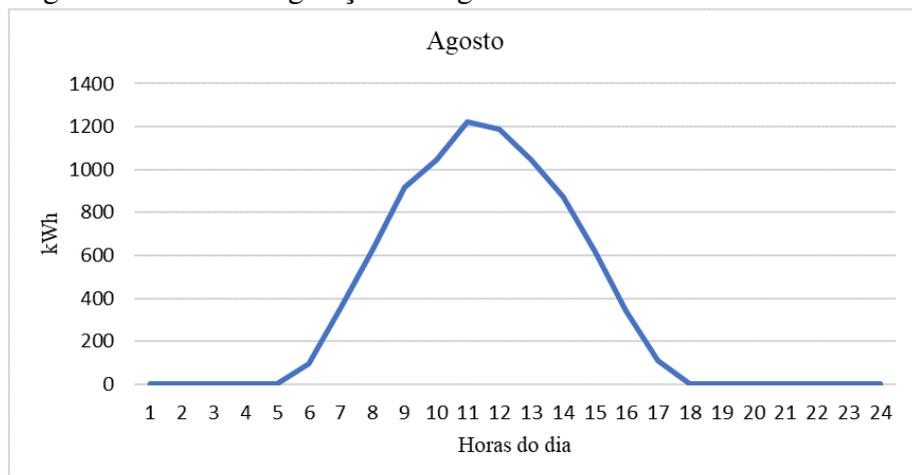
Fonte: Autoria Própria

Figura 45 – Perfil de geração em julho



Fonte: Autoria Própria

Figura 46 – Perfil de geração em agosto



Fonte: Autoria Própria

Figura 47 – Perfil de geração em setembro



Fonte: Autoria Própria

Figura 48 – Perfil de geração em outubro



Fonte: Autoria Própria

Figura 49 – Perfil de geração em novembro



Fonte: Autoria Própria

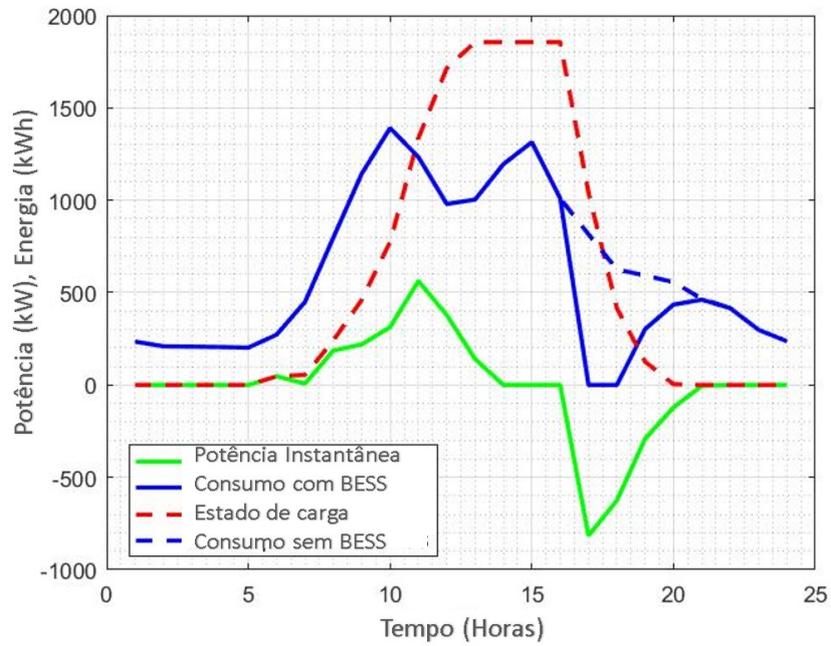
Figura 50 – Perfil de geração em dezembro



Fonte: Autoria Própria

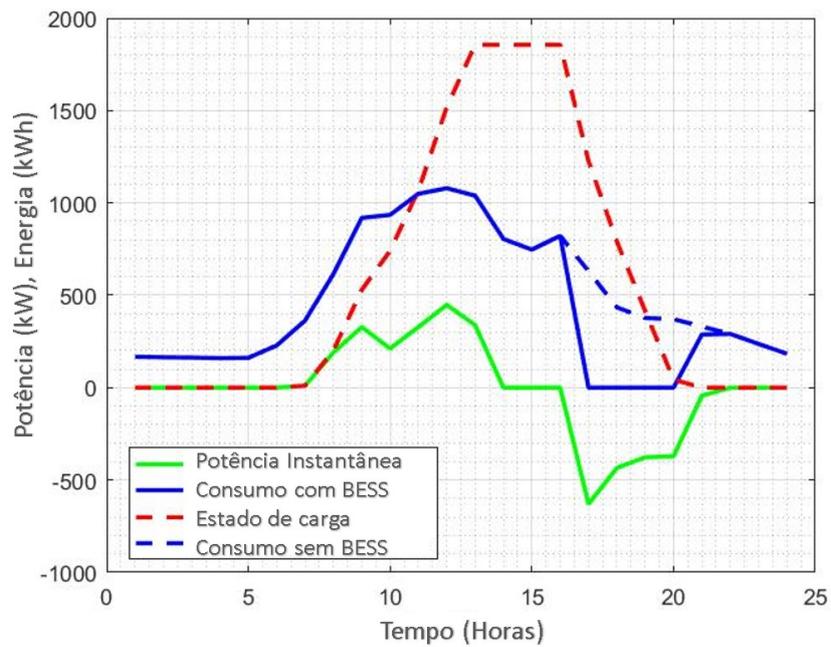
## ANEXO D – COMPORTAMENTO DOS PARAMETROS ELÉTRICOS

Figura 51 – Efeito do algoritmo genético em um dia típico de fevereiro



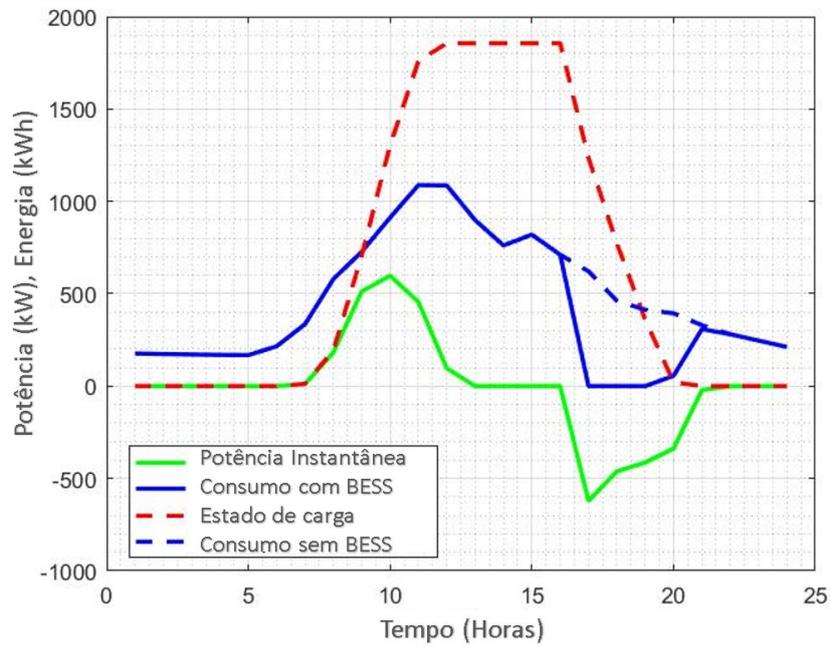
Fonte: Autoria Própria

Figura 52 – Efeito do algoritmo genético em um dia típico de março



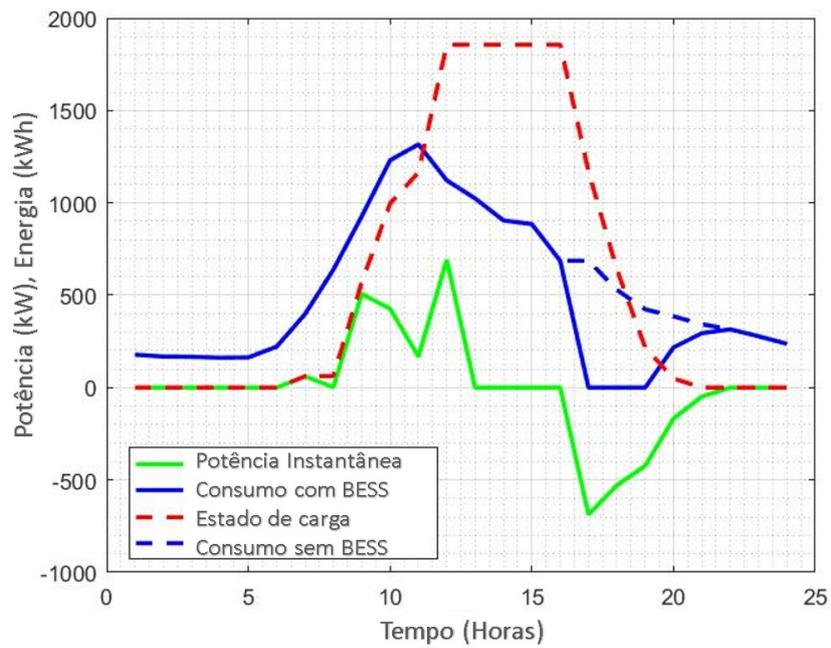
Fonte: Autoria Própria

Figura 53 – Efeito do algoritmo genético em um dia típico de abril



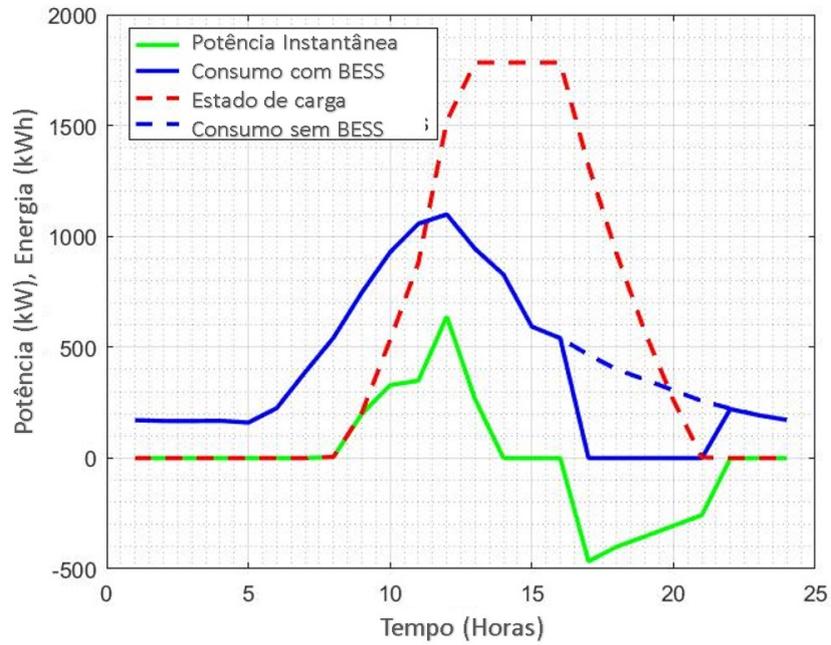
Fonte: Autoria Própria

Figura 54 – Efeito do algoritmo genético em um dia típico de maio



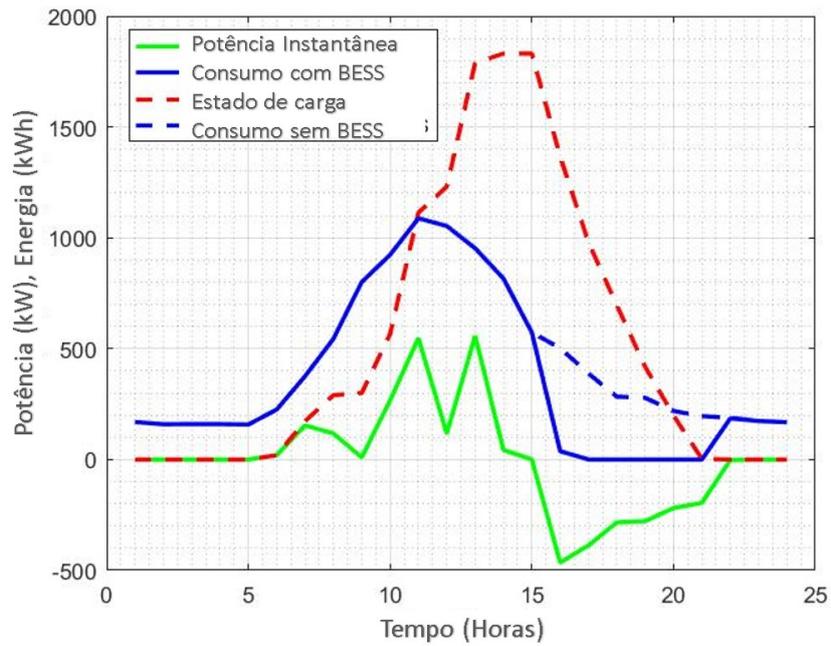
Fonte: Autoria Própria

Figura 55 – Efeito do algoritmo genético em um dia típico de junho



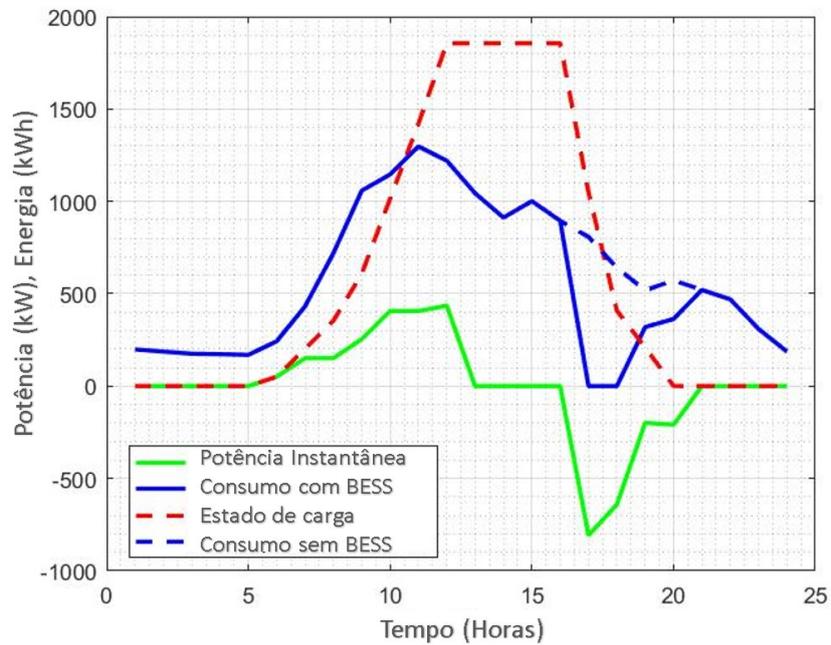
Fonte: Autoria Própria

Figura 56 – Efeito do algoritmo genético em um dia típico de julho



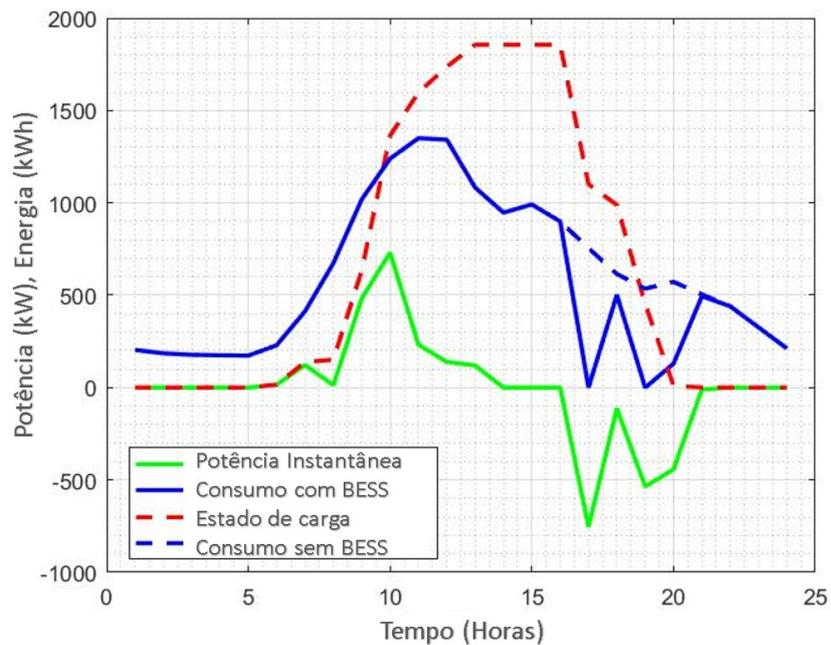
Fonte: Autoria Própria

Figura 57 – Efeito do algoritmo genético em um dia típico de agosto



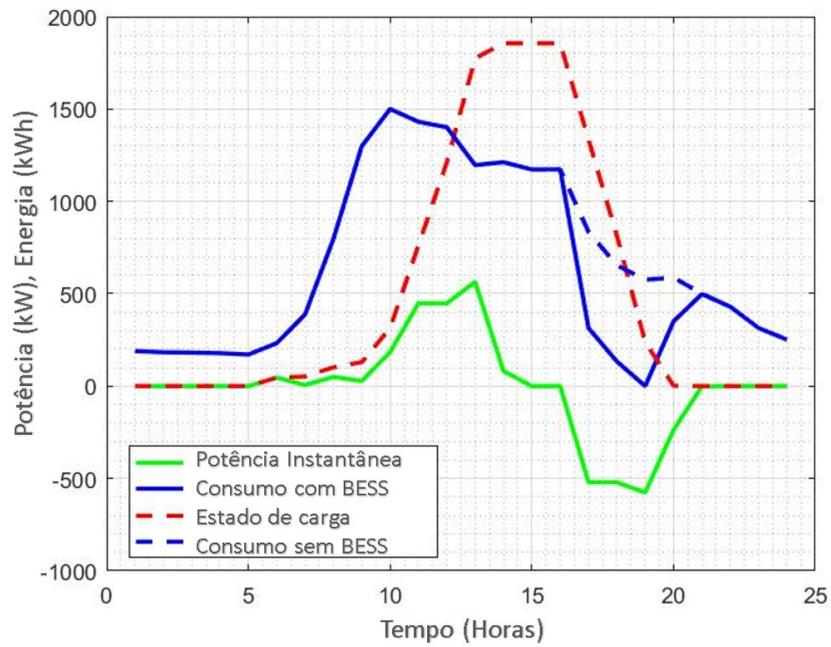
Fonte: Autoria Própria

Figura 58 – Efeito do algoritmo genético em um dia típico de setembro



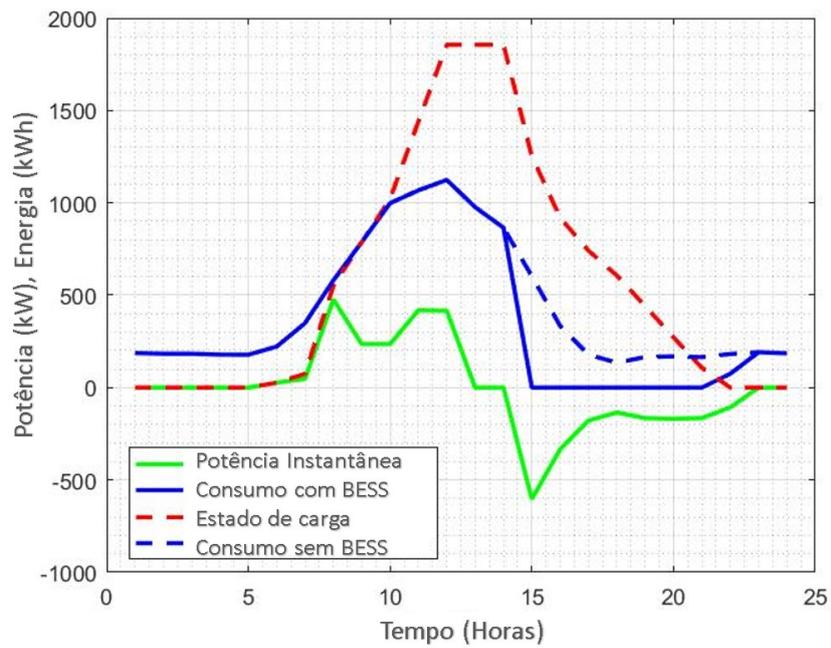
Fonte: Autoria Própria

Figura 59 – Efeito do algoritmo genético em um dia típico de outubro



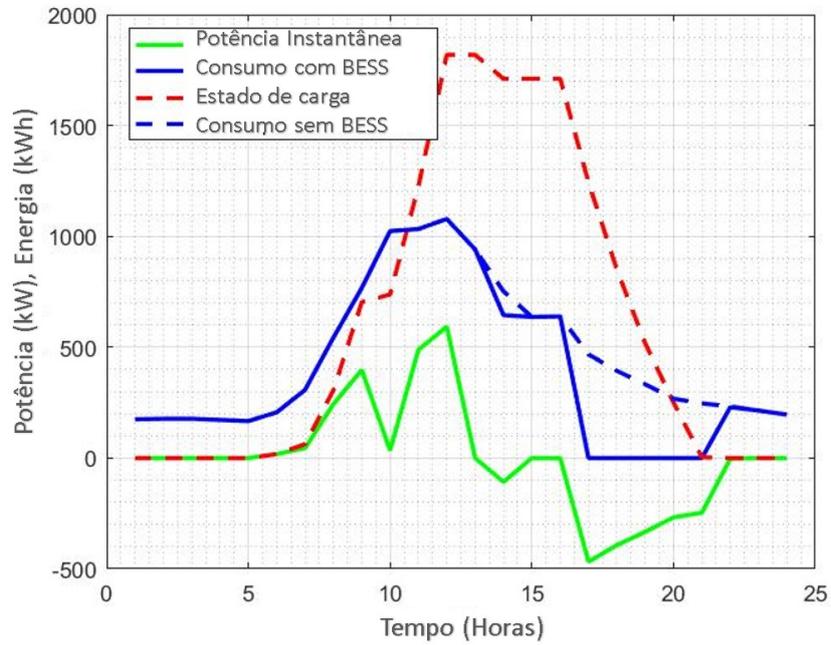
Fonte: Autoria Própria

Figura 60 – Efeito do algoritmo genético em um dia típico de novembro



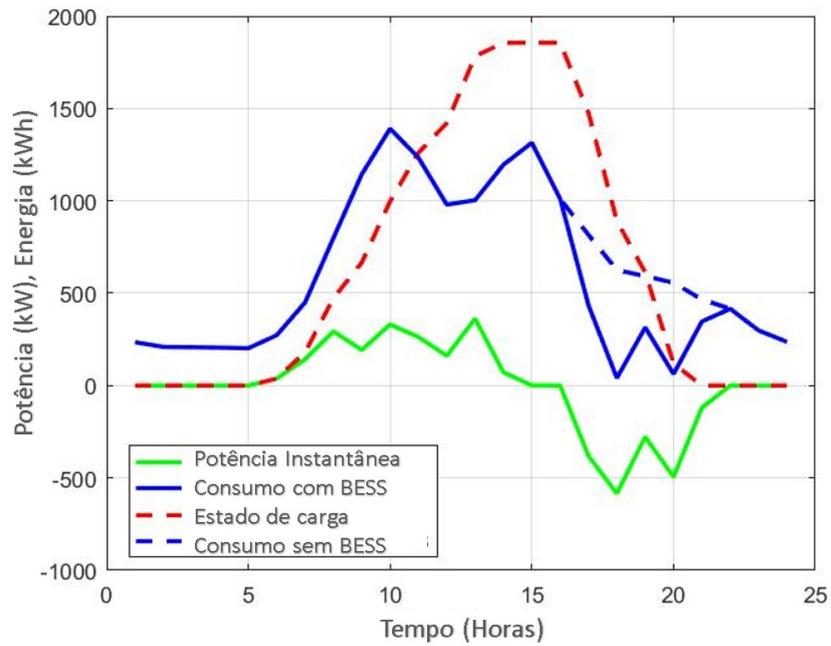
Fonte: Autoria Própria

Figura 61 – Efeito do algoritmo genético em um dia típico de dezembro



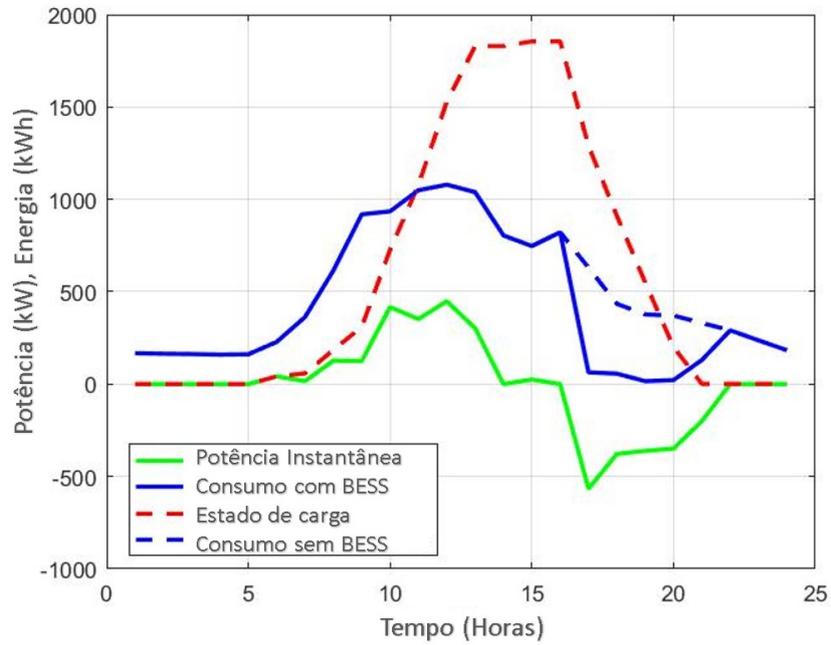
Fonte: Autoria Própria

Figura 62 – Efeito do evolução diferencial em um dia típico de fevereiro



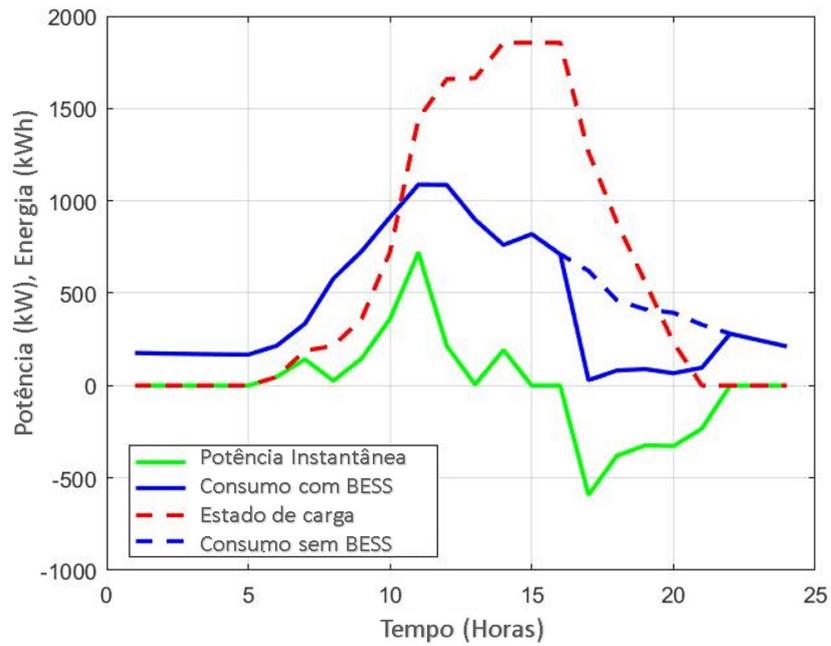
Fonte: Autoria Própria

Figura 63 – Efeito do evolução diferencial em um dia típico de março



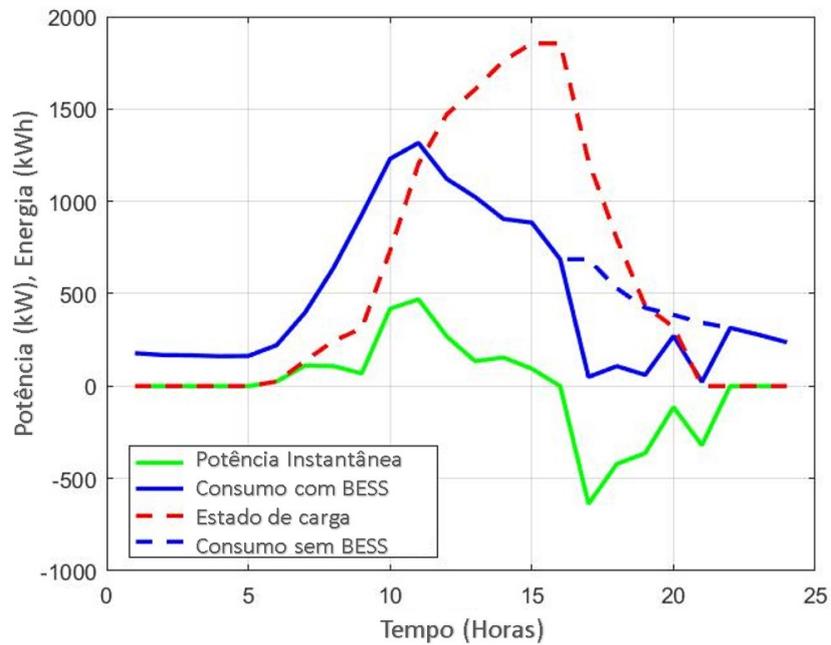
Fonte: Autoria Própria

Figura 64 – Efeito do evolução diferencial em um dia típico de abril



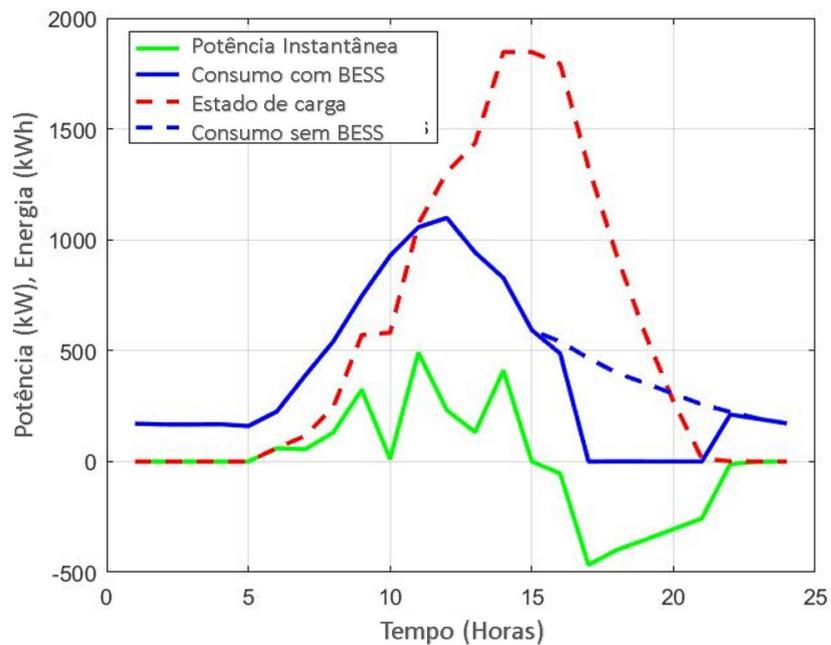
Fonte: Autoria Própria

Figura 65 – Efeito do evolução diferencial em um dia típico de maio



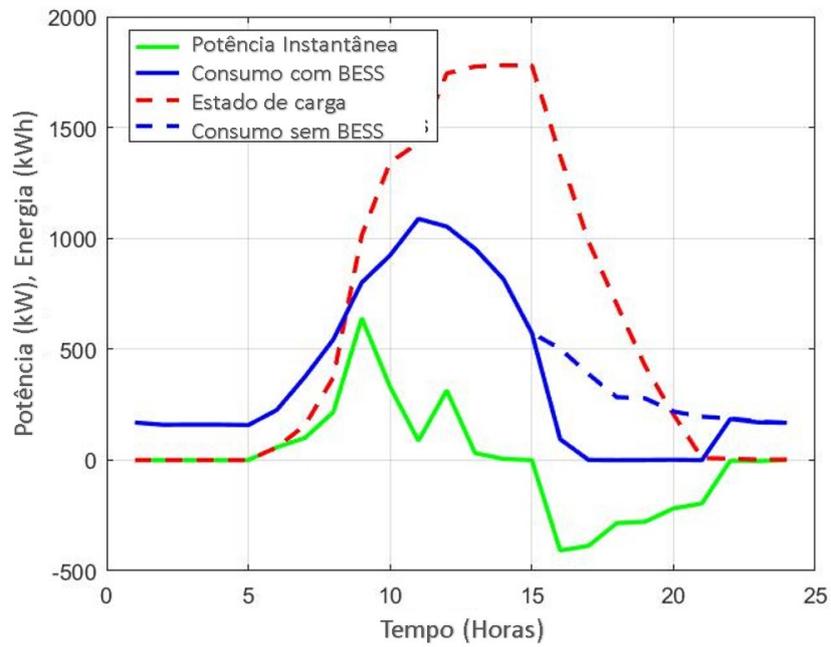
Fonte: Autoria Própria

Figura 66 – Efeito do evolução diferencial em um dia típico de junho



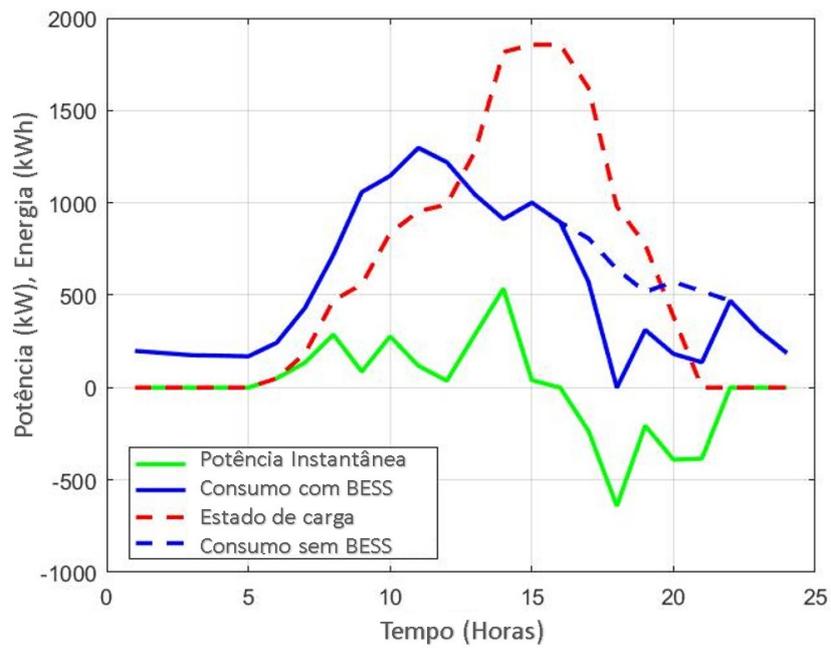
Fonte: Autoria Própria

Figura 67 – Efeito do evolução diferencial em um dia típico de julho



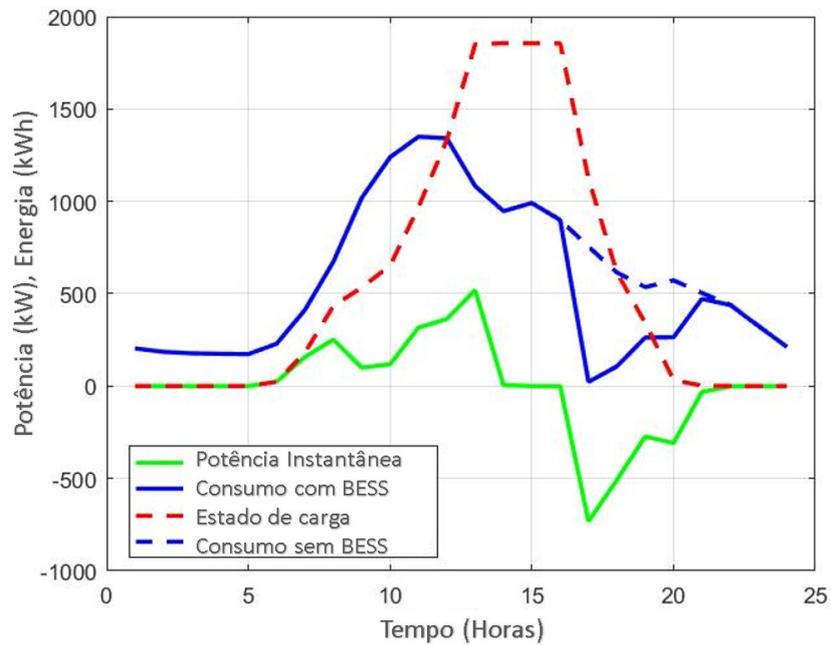
Fonte: Autoria Própria

Figura 68 – Efeito do evolução diferencial em um dia típico de agosto



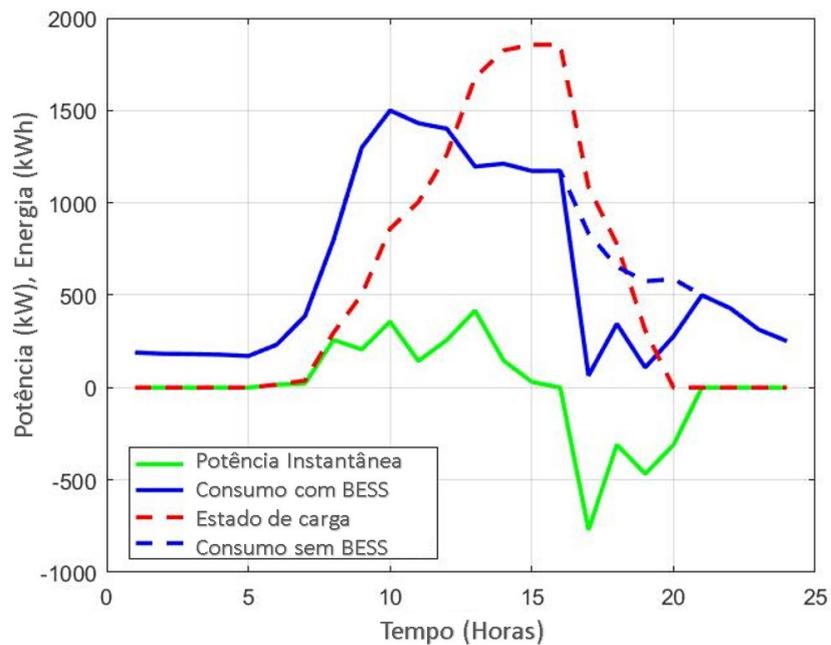
Fonte: Autoria Própria

Figura 69 – Efeito do evolução diferencial em um dia típico de setembro



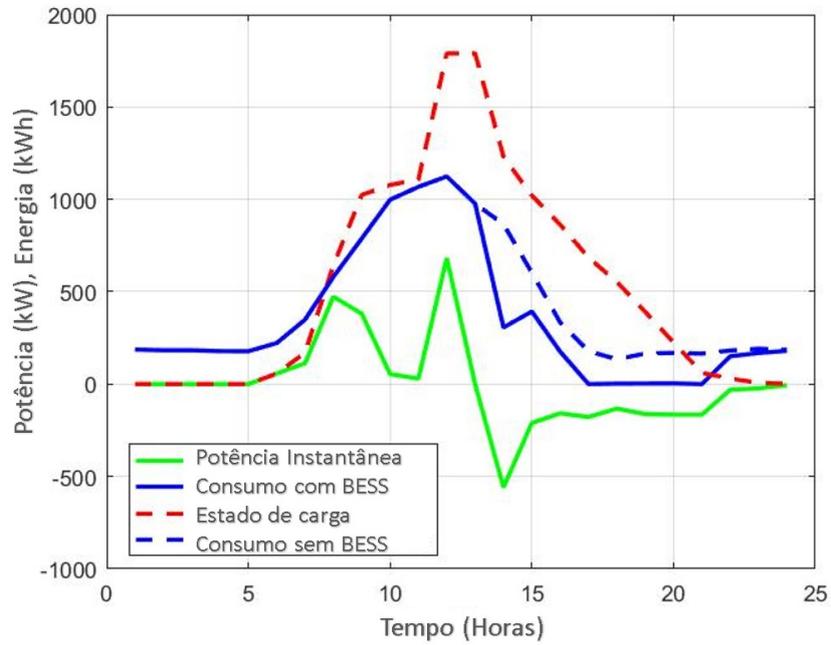
Fonte: Autoria Própria

Figura 70 – Efeito do evolução diferencial em um dia típico de outubro



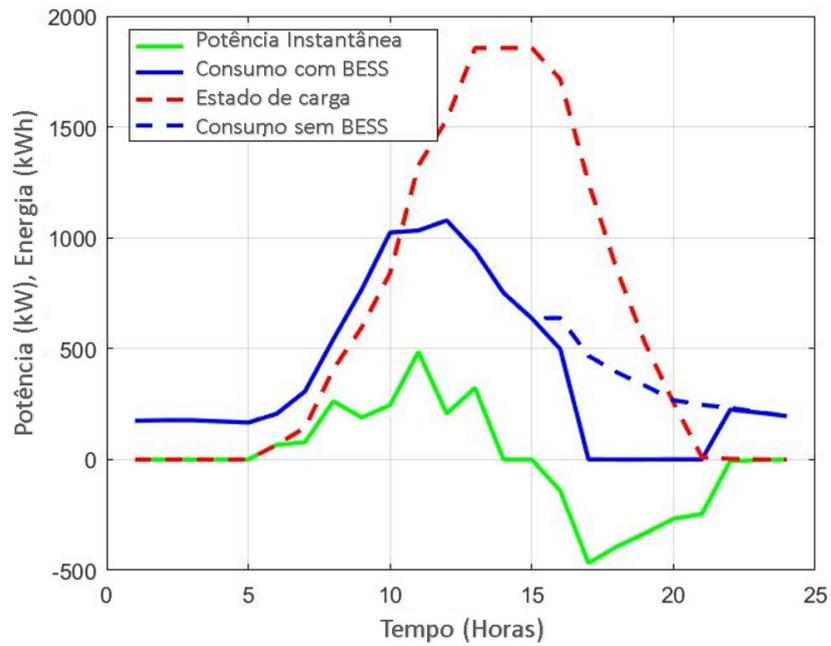
Fonte: Autoria Própria

Figura 71 – Efeito do evolução diferencial em um dia típico de novembro



Fonte: Autoria Própria

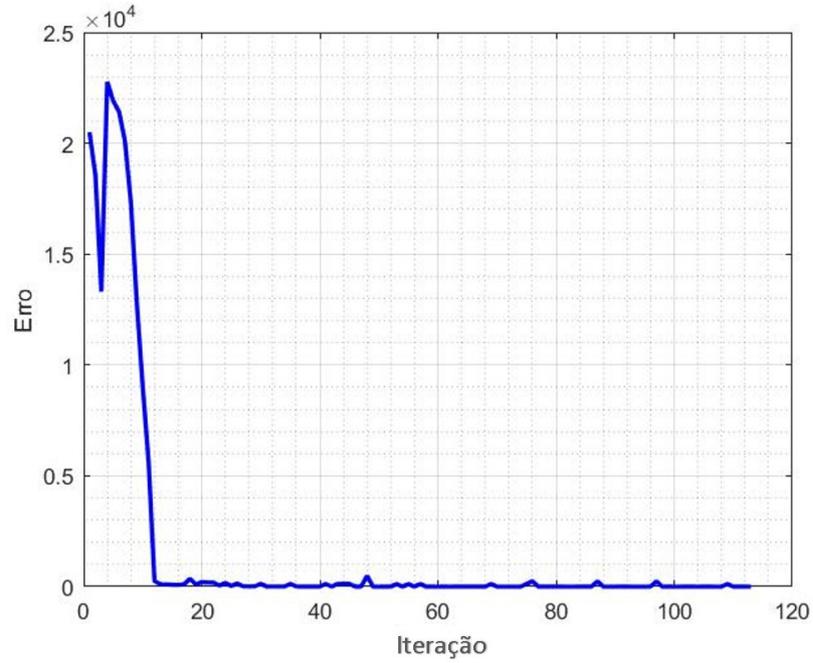
Figura 72 – Efeito do evolução diferencial em um dia típico de dezembro



Fonte: Autoria Própria

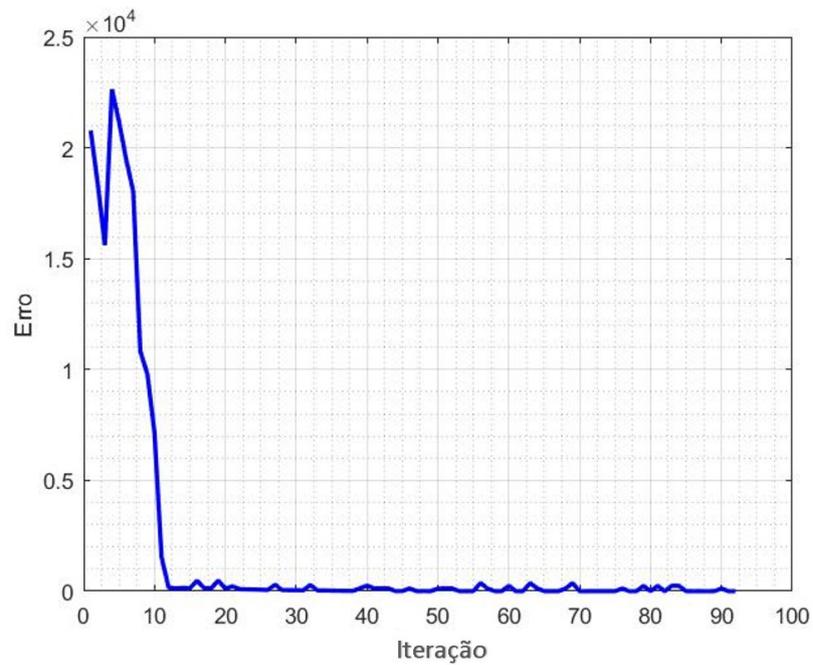
**ANEXO E – CONVERGÊNCIA DO ERRO**

Figura 73 – Comportamento do erro do algoritmo genético num dia típico de fevereiro



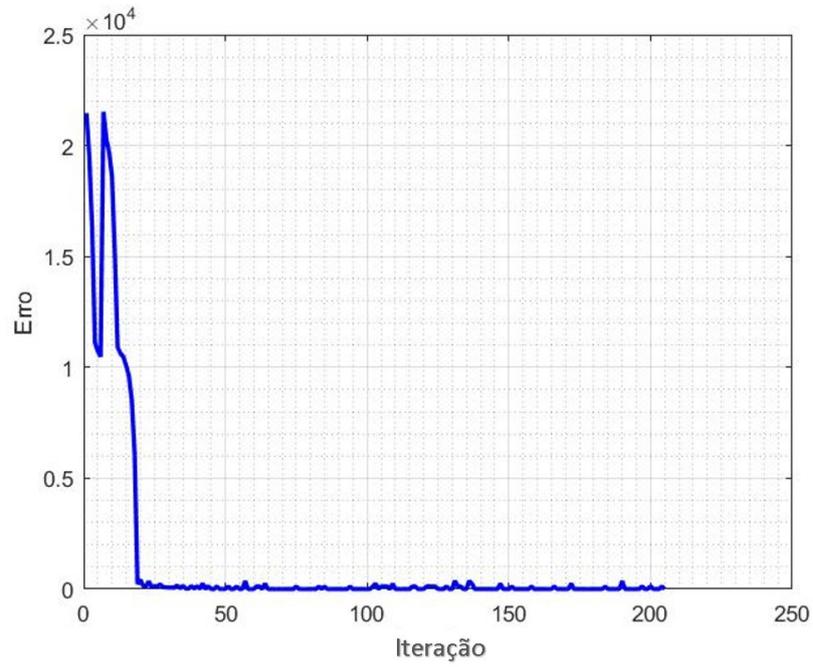
Fonte: Autoria Própria

Figura 74 – Comportamento do erro do algoritmo genético num dia típico de março



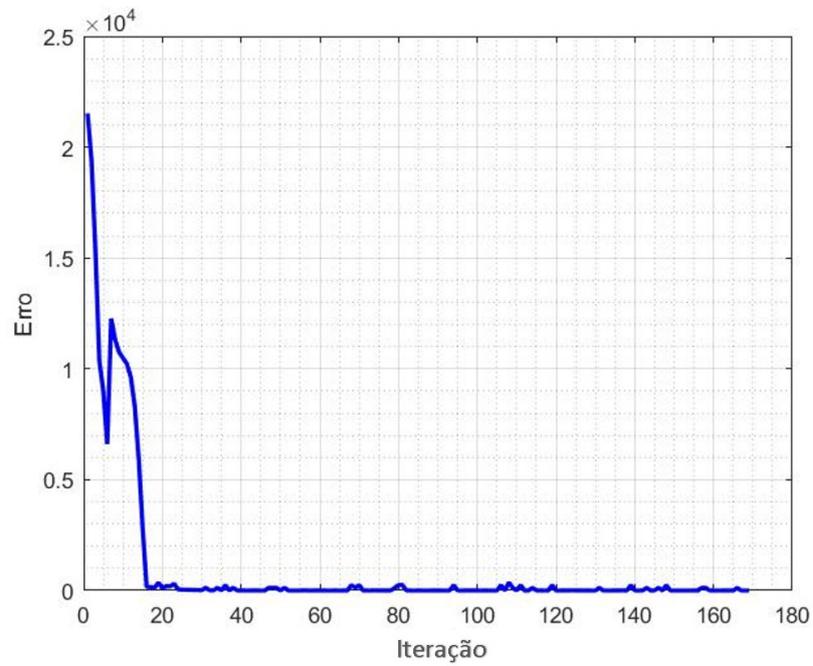
Fonte: Autoria Própria

Figura 75 – Comportamento do erro do algoritmo genético num dia típico de abril



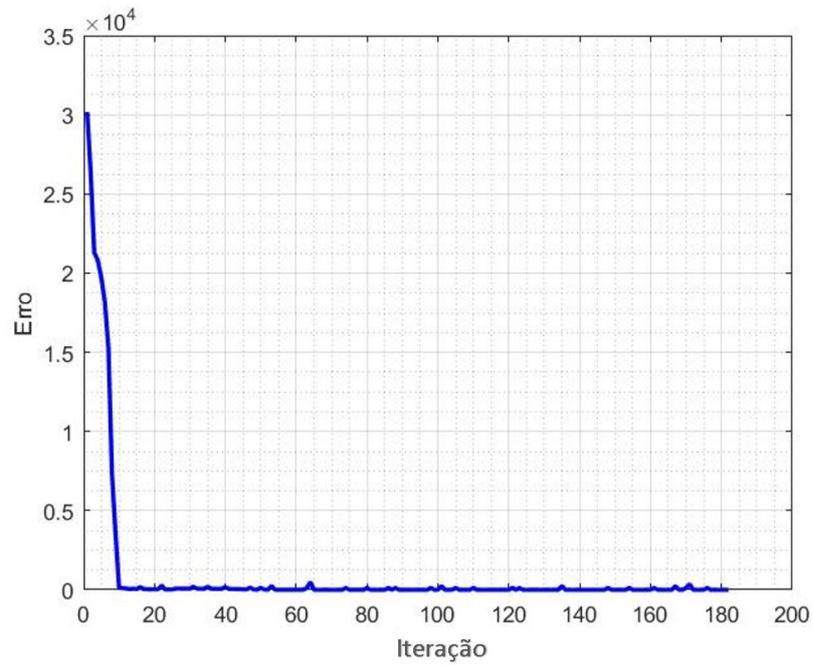
Fonte: Autoria Própria

Figura 76 – Comportamento do erro do algoritmo genético num dia típico de maio



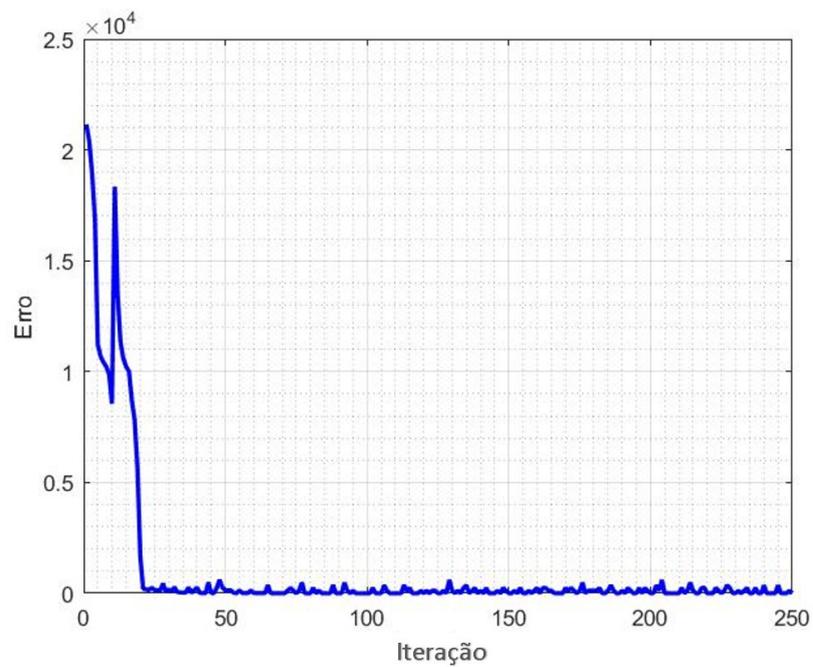
Fonte: Autoria Própria

Figura 77 – Comportamento do erro do algoritmo genético num dia típico de junho



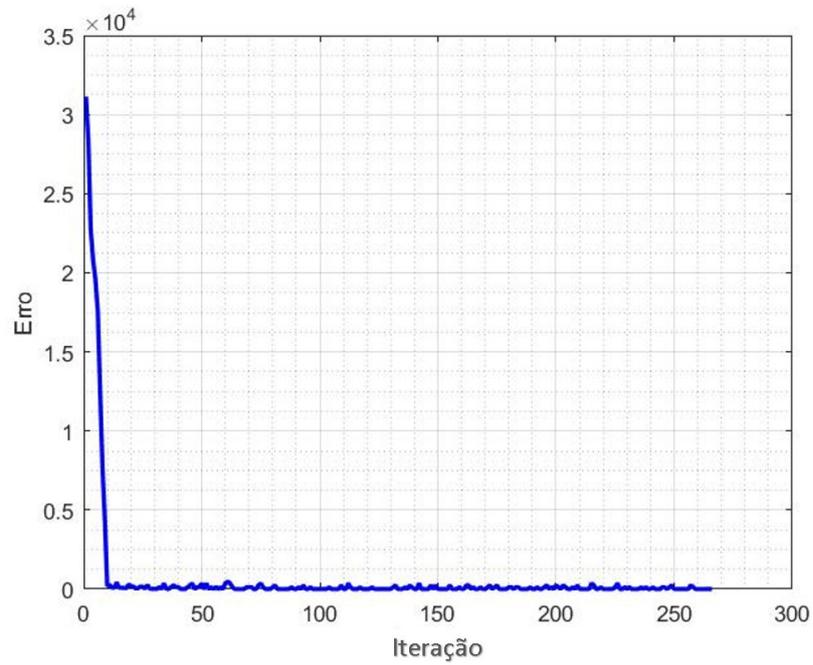
Fonte: Autoria Própria

Figura 78 – Comportamento do erro do algoritmo genético num dia típico de julho



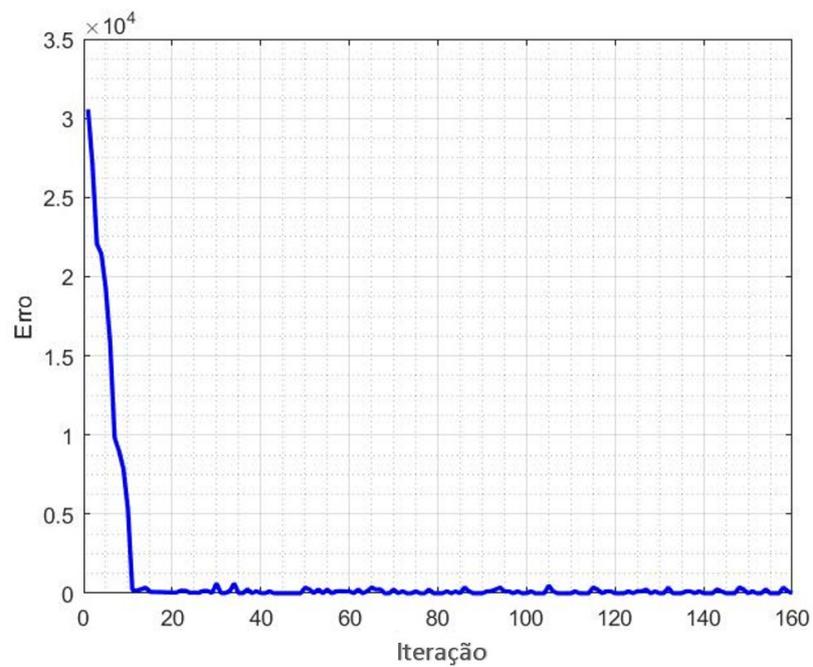
Fonte: Autoria Própria

Figura 79 – Comportamento do erro do algoritmo genético num dia típico de agosto



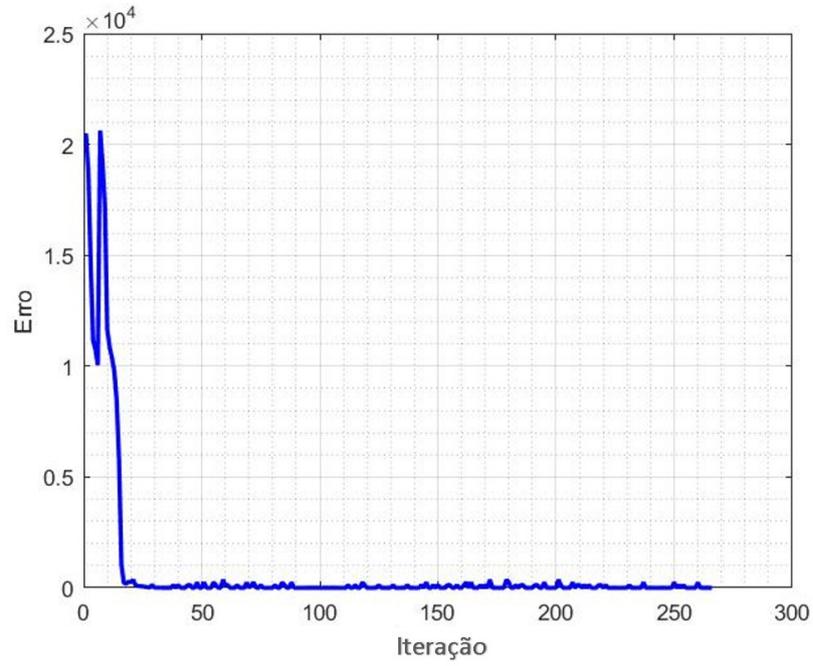
Fonte: Autoria Própria

Figura 80 – Comportamento do erro do algoritmo genético num dia típico de setembro



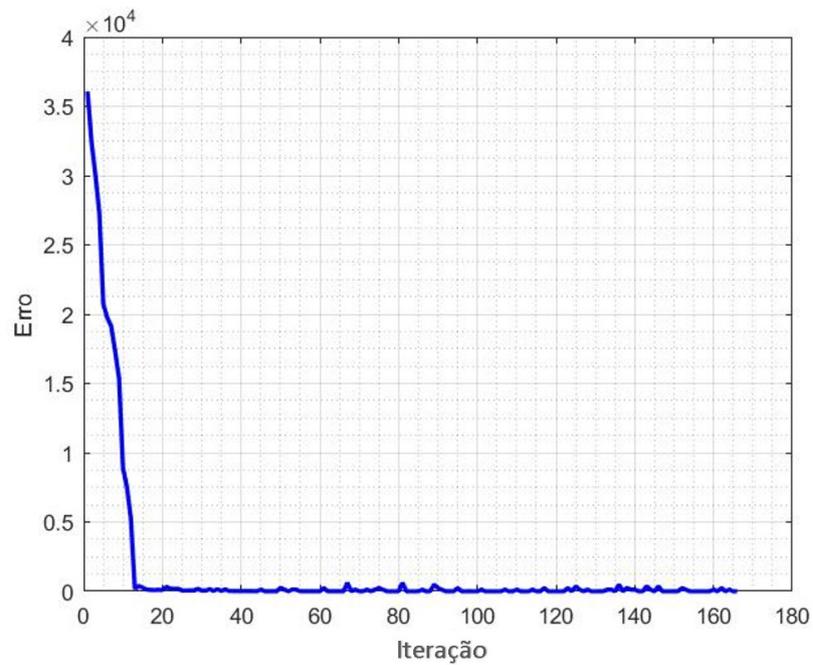
Fonte: Autoria Própria

Figura 81 – Comportamento do erro do algoritmo genético num dia típico de outubro



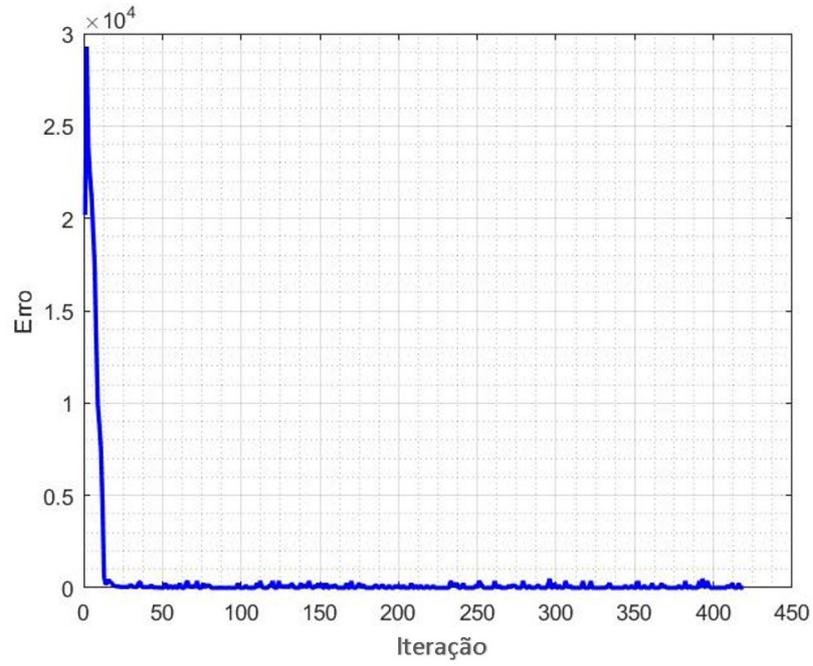
Fonte: Autoria Própria

Figura 82 – Comportamento do erro do algoritmo genético num dia típico de novembro



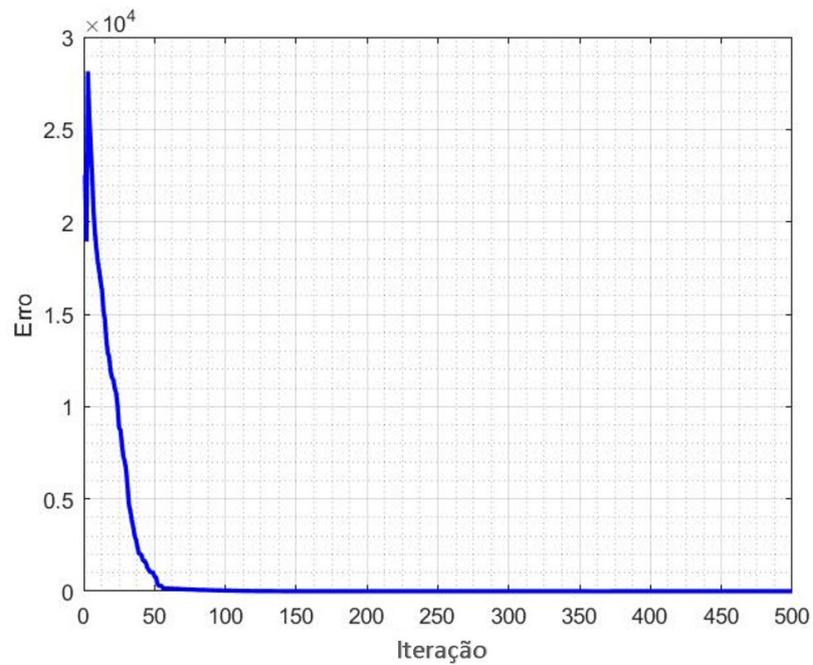
Fonte: Autoria Própria

Figura 83 – Comportamento do erro do algoritimo genético num dia típico de dezembro



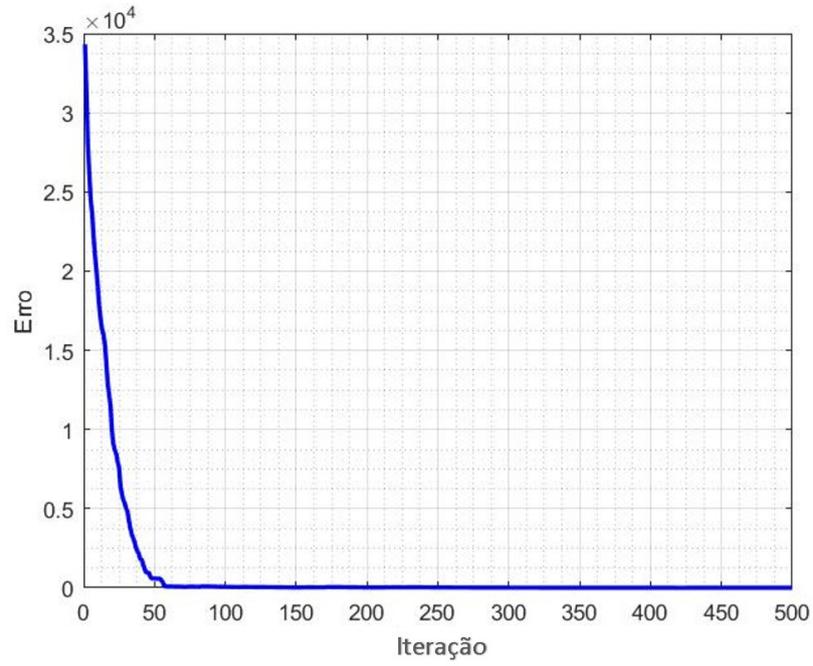
Fonte: Autoria Própria

Figura 84 – Comportamento do erro do evolução diferencial num dia típico de fevereiro



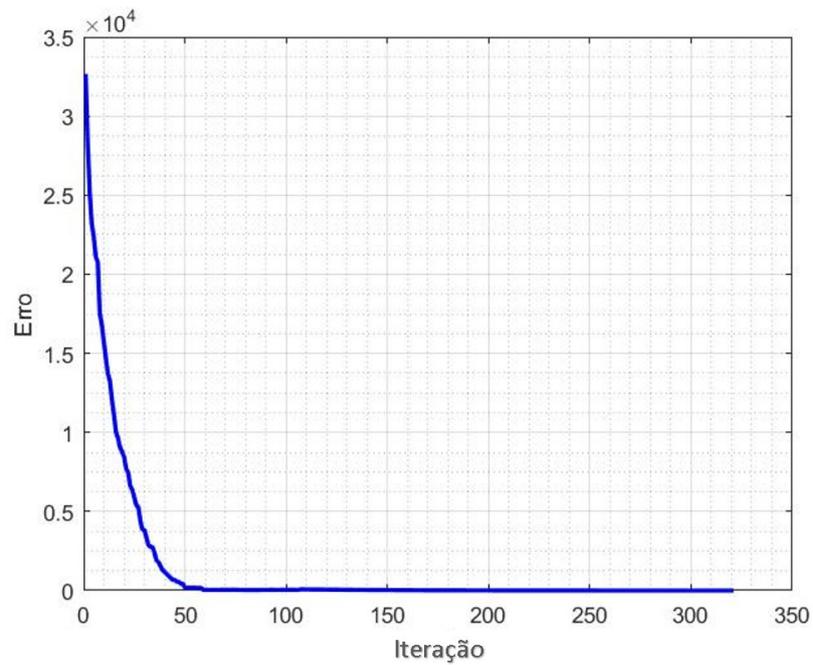
Fonte: Autoria Própria

Figura 85 – Comportamento do erro do evolução diferencial num dia típico de março



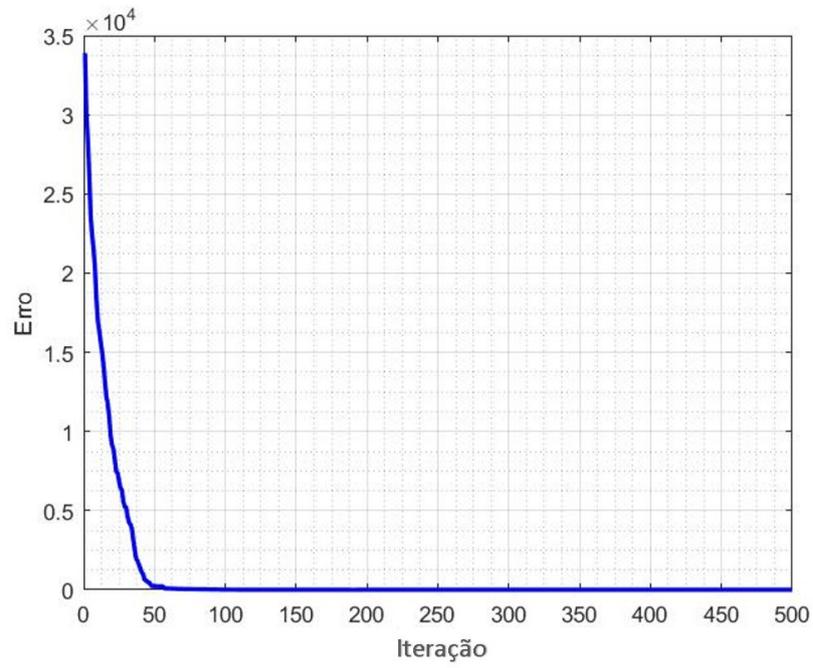
Fonte: Autoria Própria

Figura 86 – Comportamento do erro do evolução diferencial num dia típico de abril



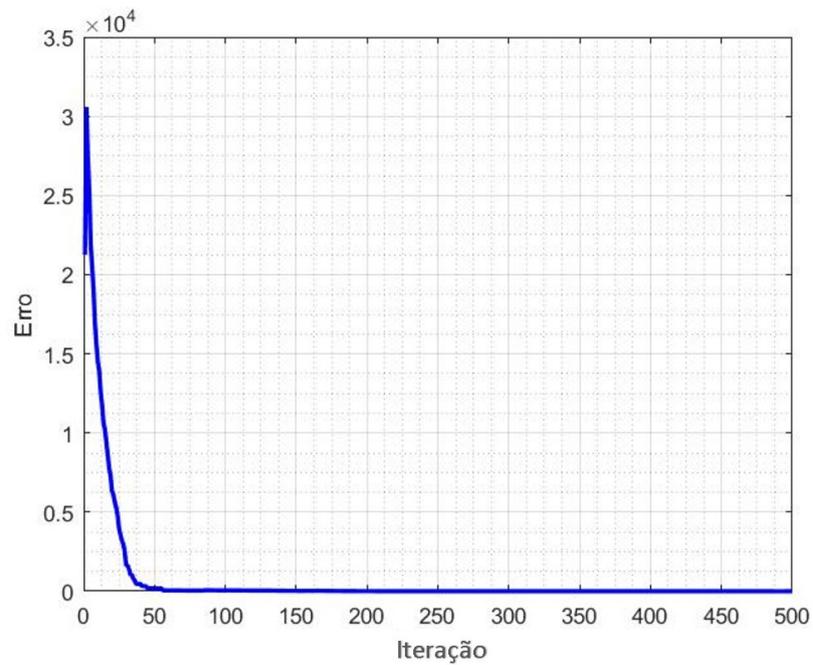
Fonte: Autoria Própria

Figura 87 – Comportamento do erro do evolução diferencial num dia típico de maio



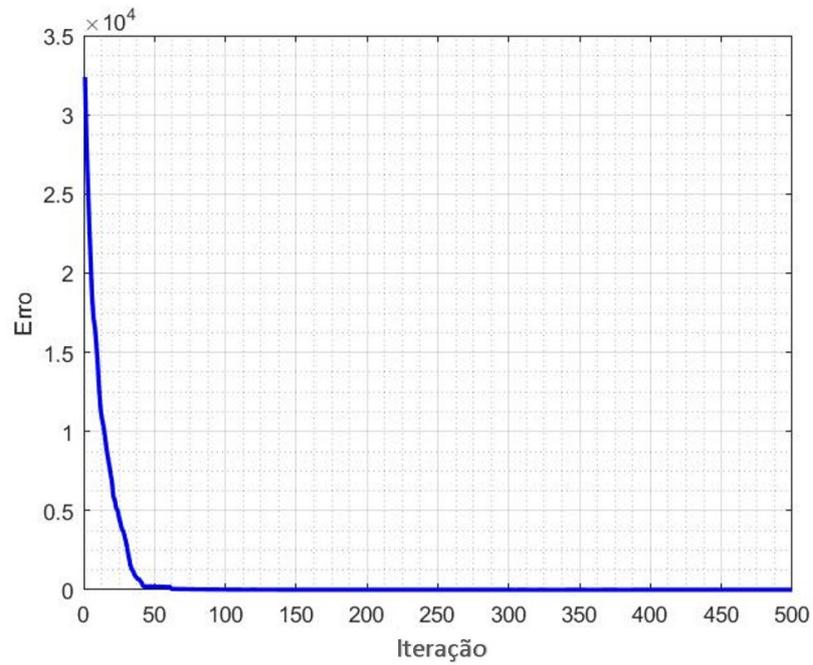
Fonte: Autoria Própria

Figura 88 – Comportamento do erro do evolução diferencial num dia típico de junho



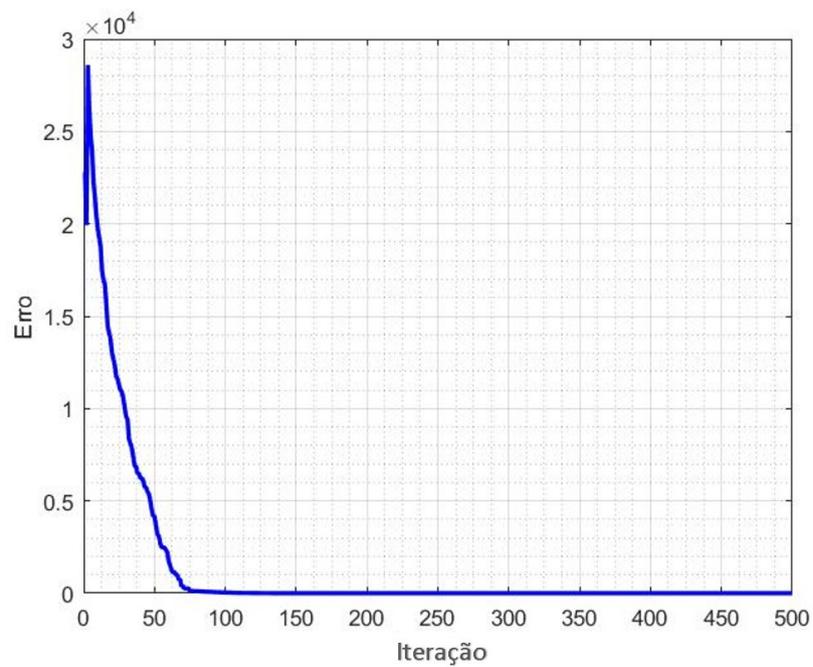
Fonte: Autoria Própria

Figura 89 – Comportamento do erro do evolução diferencial num dia típico de julho



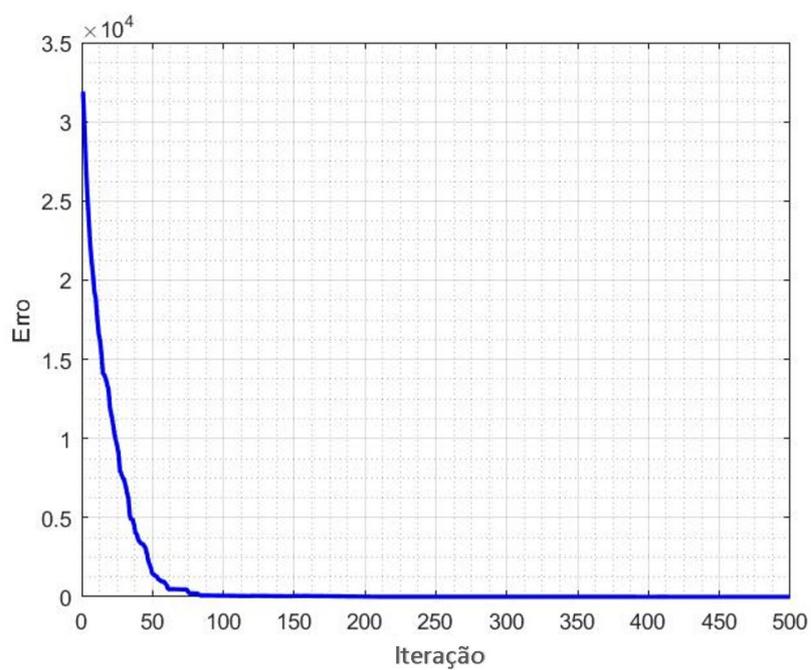
Fonte: Autoria Própria

Figura 90 – Comportamento do erro do evolução diferencial num dia típico de agosto



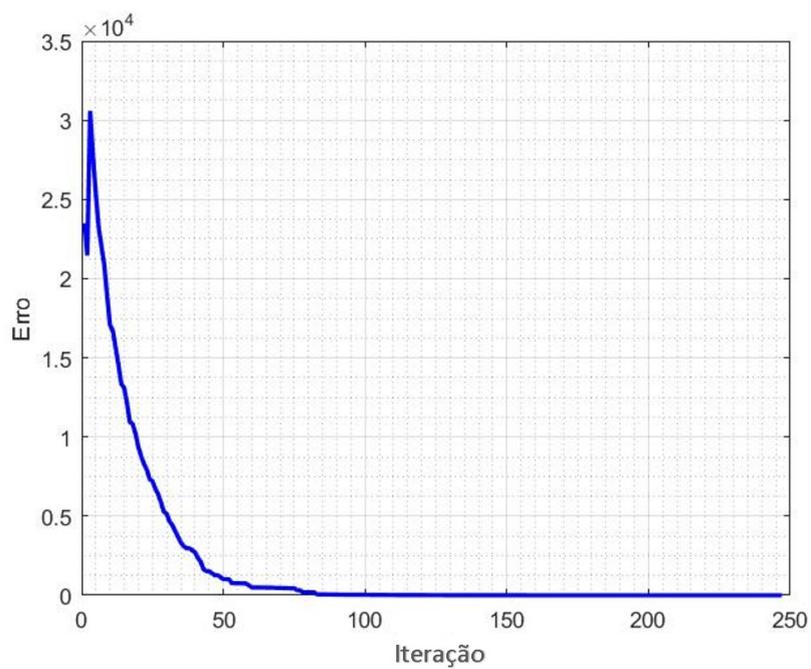
Fonte: Autoria Própria

Figura 91 – Comportamento do erro do evolução diferencial num dia típico de setembro



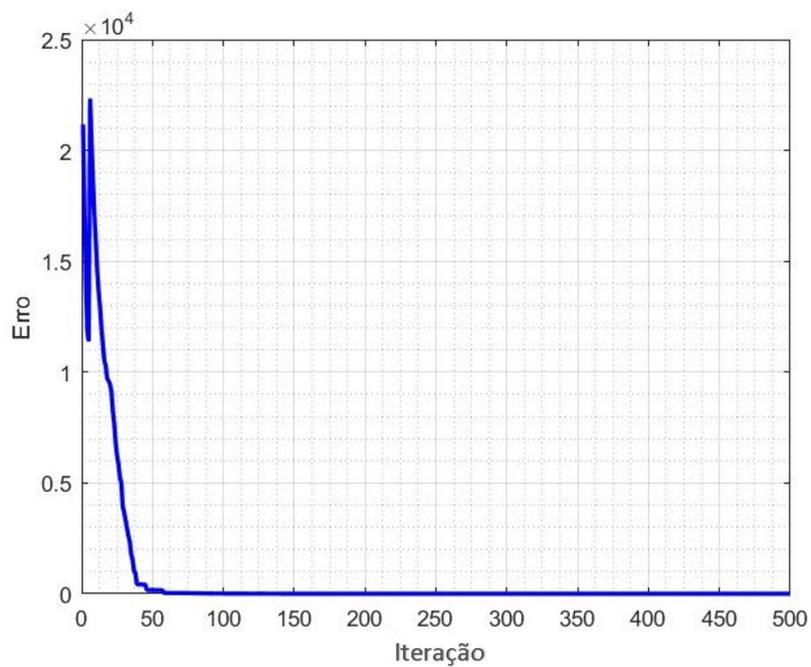
Fonte: Autoria Própria

Figura 92 – Comportamento do erro do evolução diferencial num dia típico de outubro



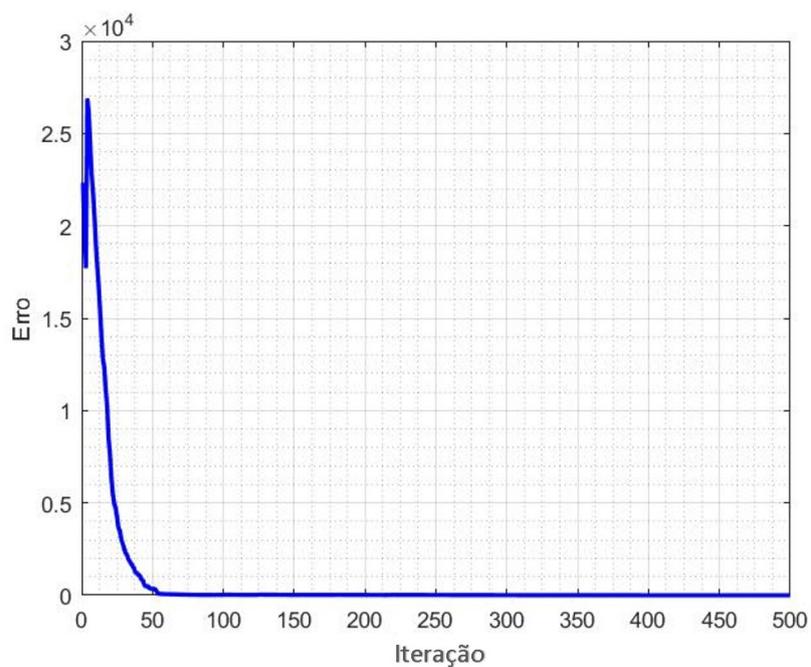
Fonte: Autoria Própria

Figura 93 – Comportamento do erro do evolução diferencial num dia típico de novembro



Fonte: Autoria Própria

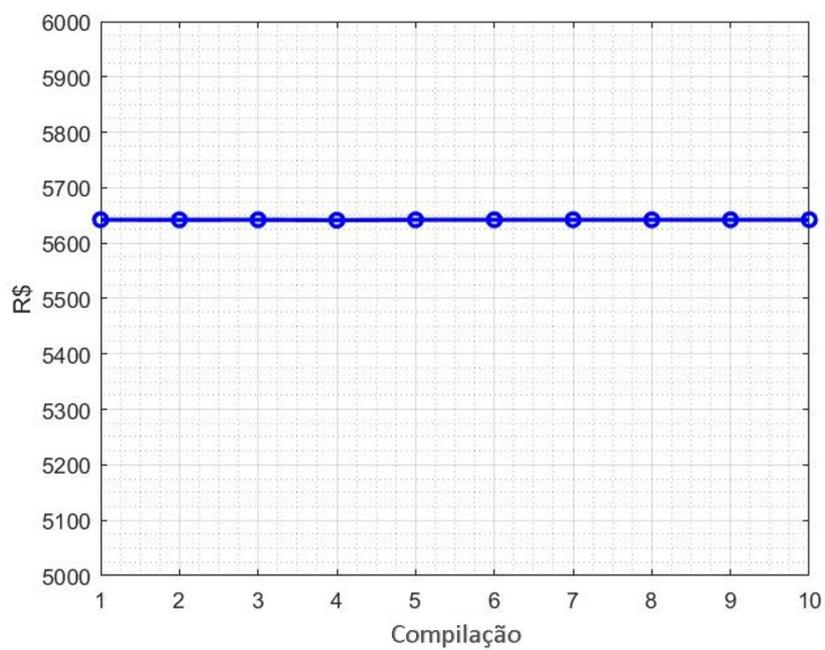
Figura 94 – Comportamento do erro do evolução diferencial num dia típico de dezembro



Fonte: Autoria Própria

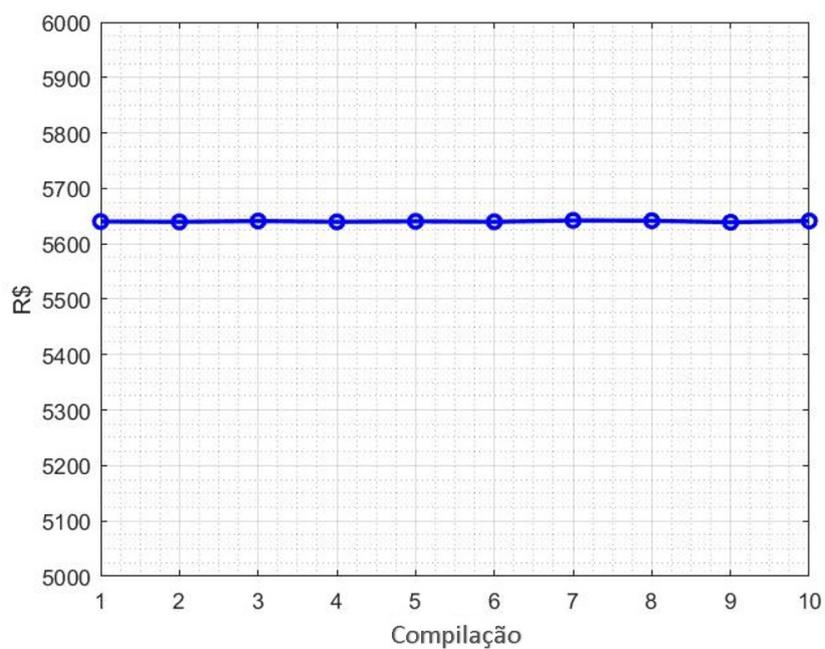
**ANEXO F – CONSISTÊNCIA DO RESULTADO AO LONGO DE 10 COMPILAÇÕES**

Figura 95 – Consistência do algoritmo genético para o mês de fevereiro



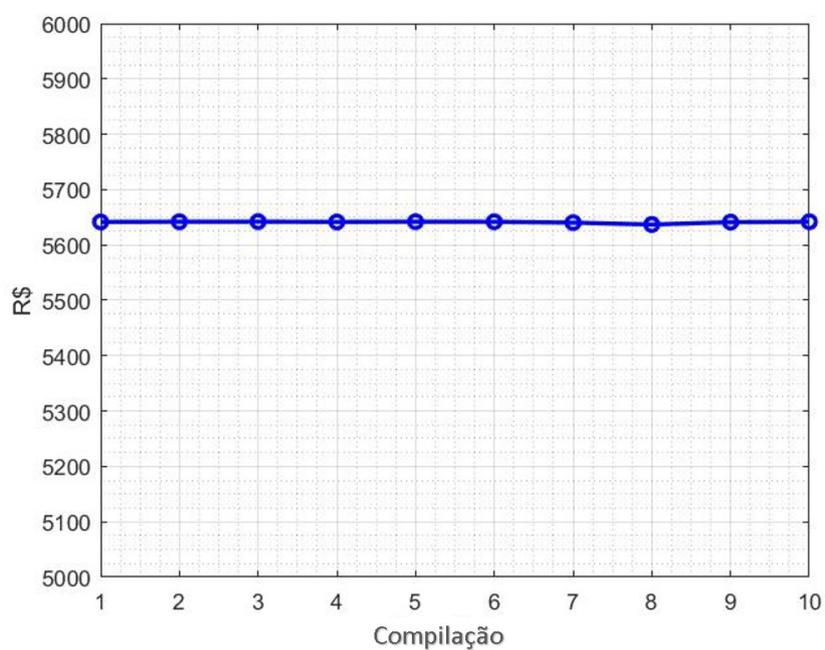
Fonte: Autoria Própria

Figura 96 – Consistência do algoritmo genético para o mês de março



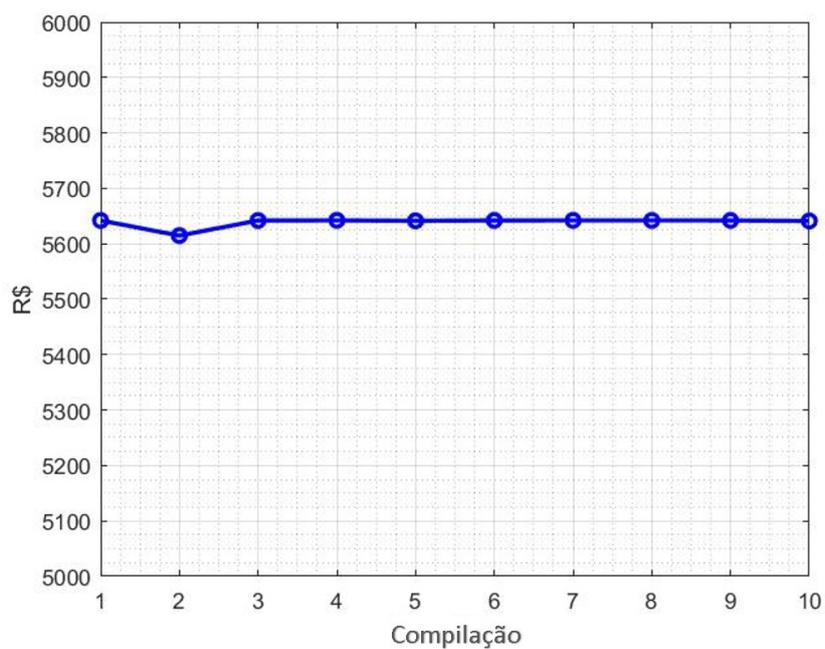
Fonte: Autoria Própria

Figura 97 – Consistência do algoritmo genético para o mês de abril



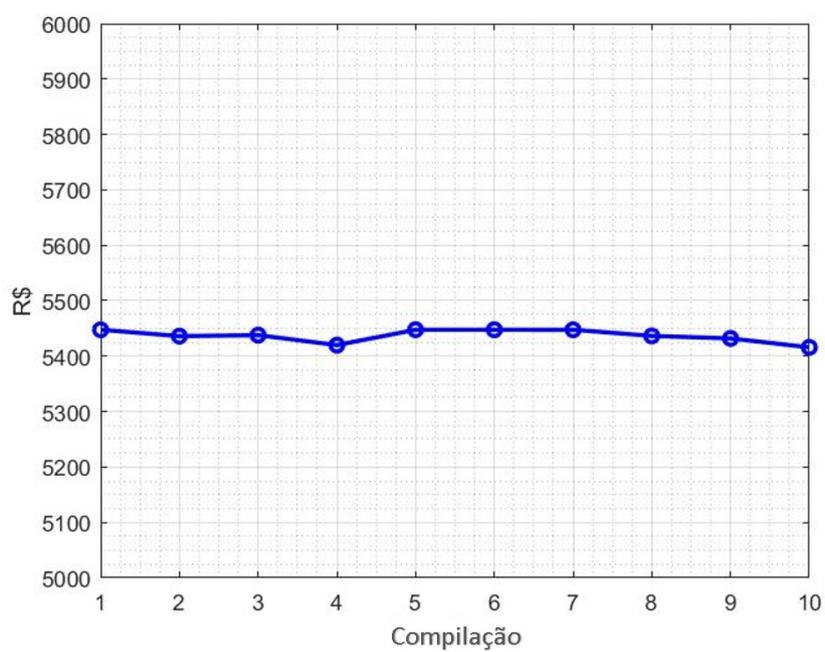
Fonte: Autoria Própria

Figura 98 – Consistência do algoritmo genético para o mês de maio



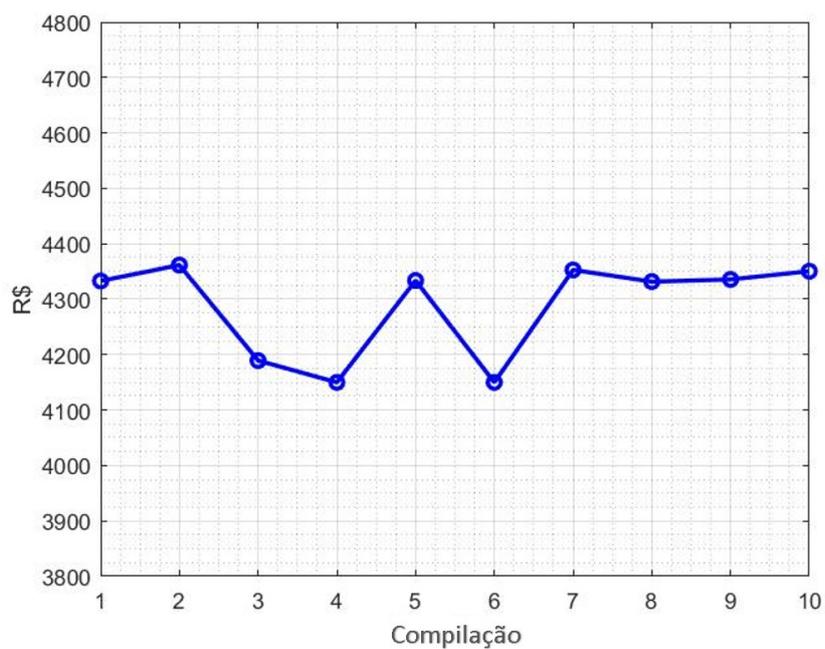
Fonte: Autoria Própria

Figura 99 – Consistência do algoritmo genético para o mês de junho



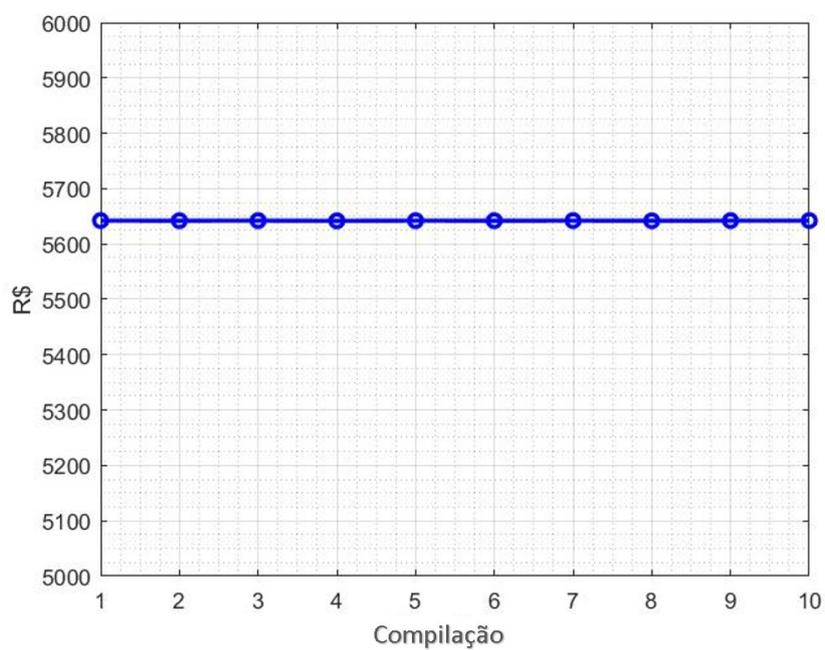
Fonte: Autoria Própria

Figura 100 – Consistência do algoritmo genético para o mês de julho



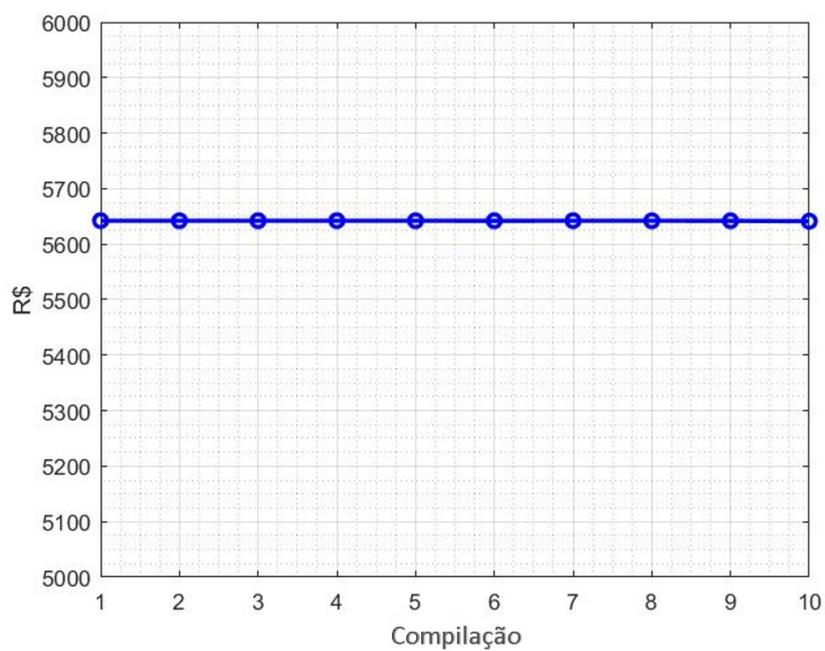
Fonte: Autoria Própria

Figura 101 – Consistência do algoritmo genético para o mês de agosto



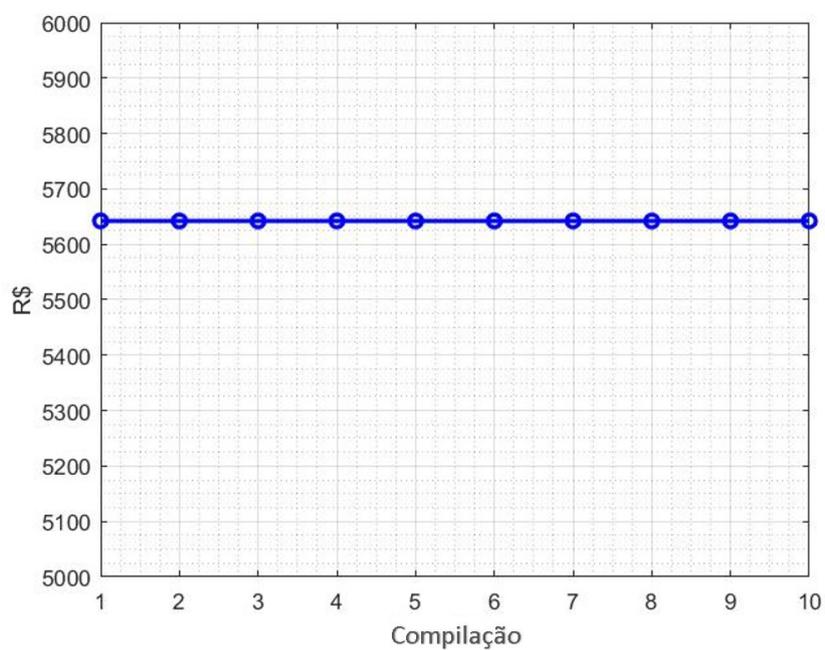
Fonte: Autoria Própria

Figura 102 – Consistência do algoritmo genético para o mês de setembro



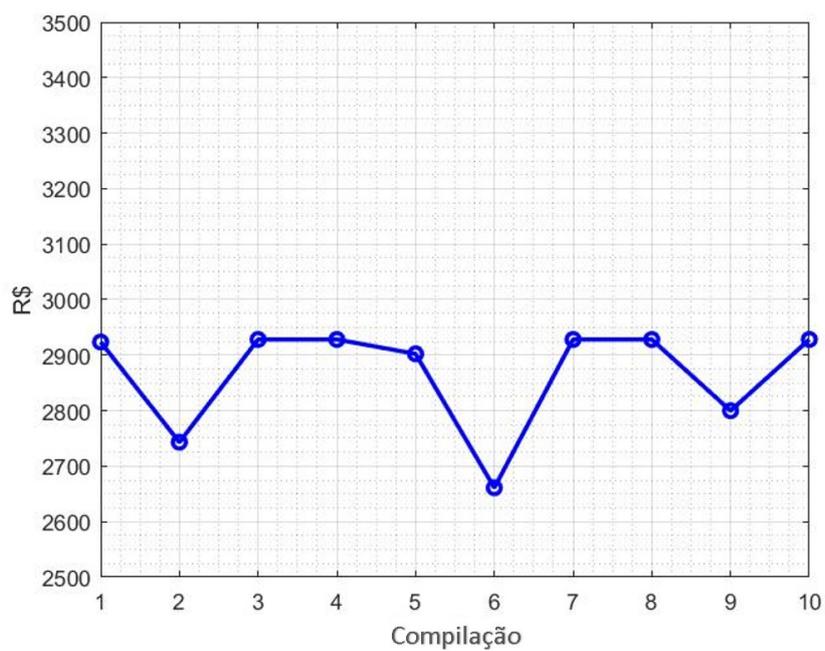
Fonte: Autoria Própria

Figura 103 – Consistência do algoritmo genético para o mês de outubro



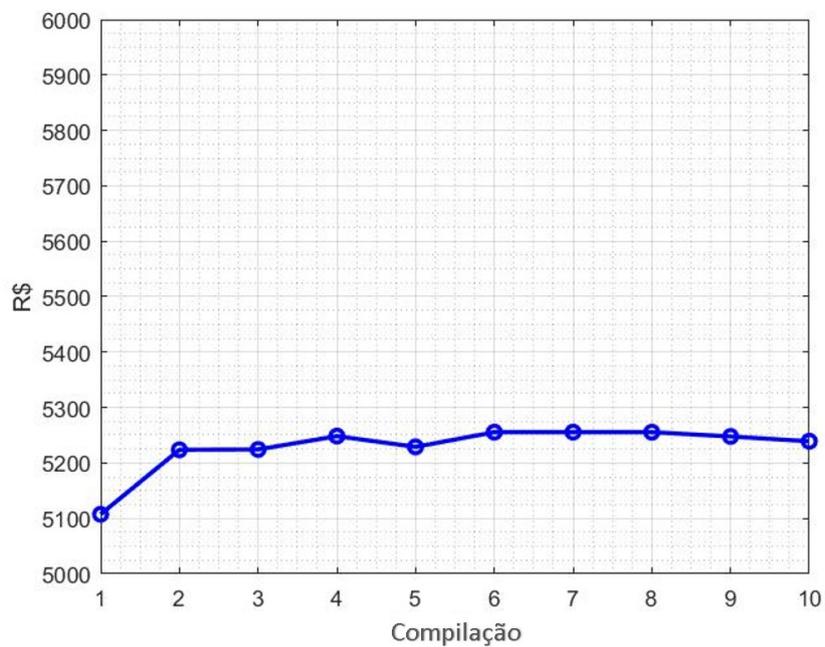
Fonte: Autoria Própria

Figura 104 – Consistência do algoritmo genético para o mês de novembro



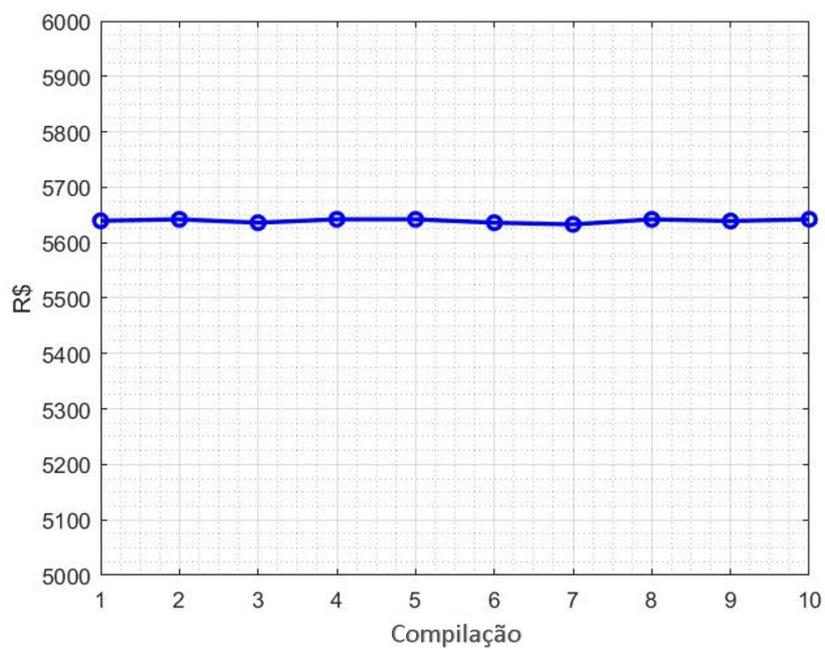
Fonte: Autoria Própria

Figura 105 – Consistência do algoritmo genético para o mês de dezembro



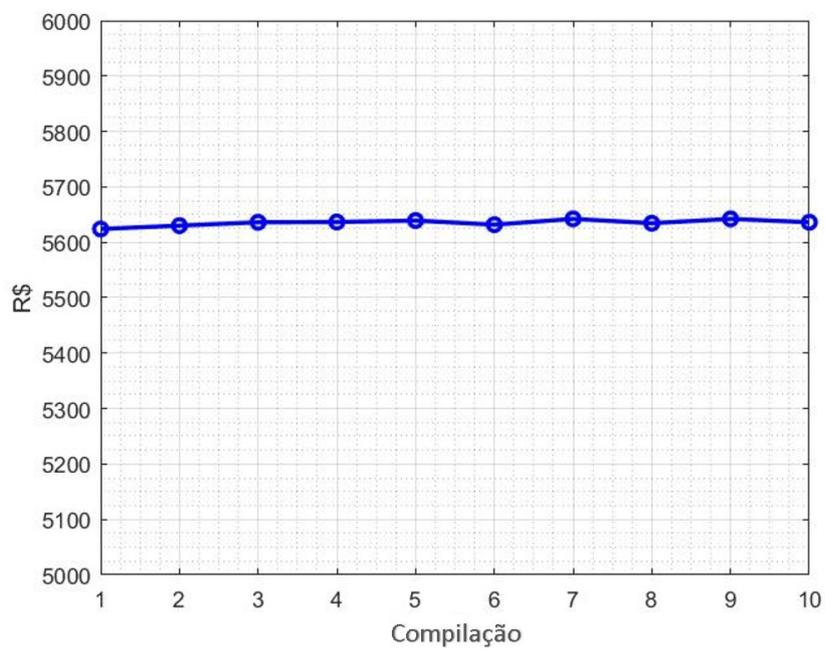
Fonte: Autoria Própria

Figura 106 – Consistência do evolução diferencial para o mês de fevereiro



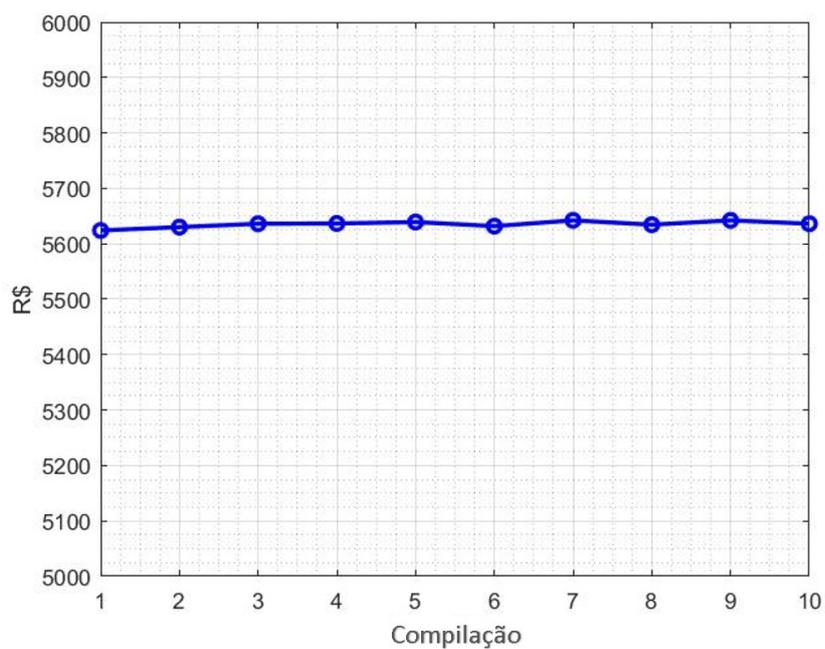
Fonte: Autoria Própria

Figura 107 – Consistência do evolução diferencial para o mês de março



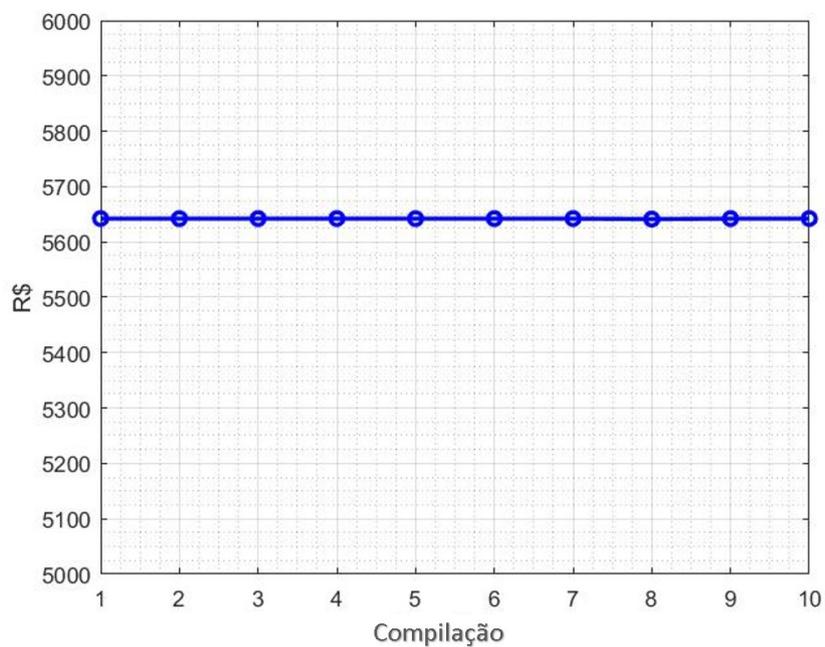
Fonte: Autoria Própria

Figura 108 – Consistência do evolução diferencial para o mês de março



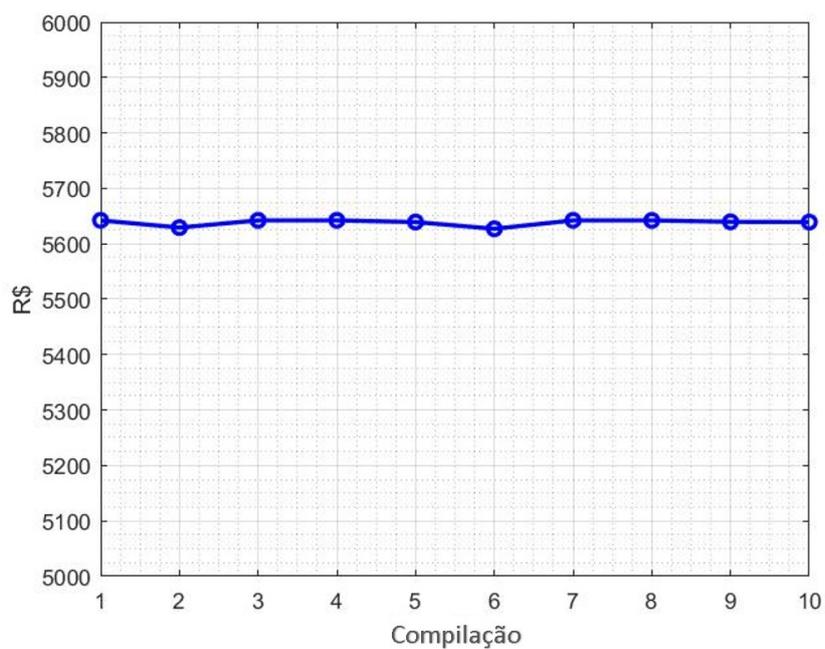
Fonte: Autoria Própria

Figura 109 – Consistência do evolução diferencial para o mês de abril



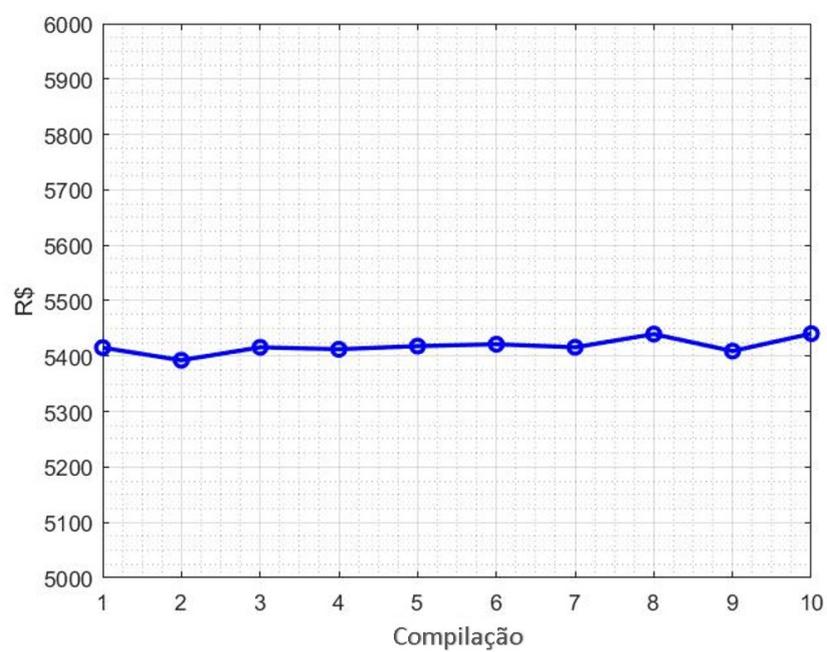
Fonte: Autoria Própria

Figura 110 – Consistência do evolução diferencial para o mês de maio



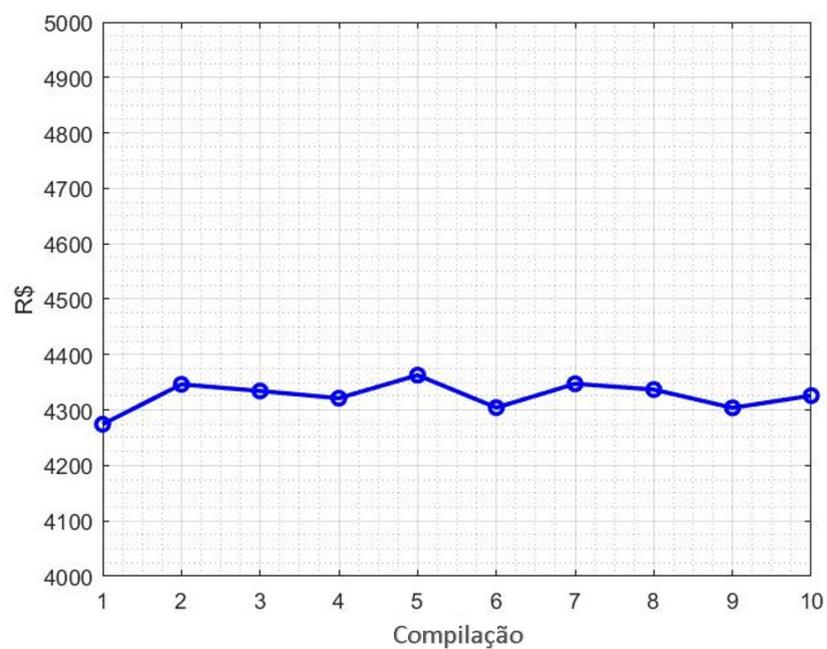
Fonte: Autoria Própria

Figura 111 – Consistência do evolução diferencial para o mês de junho



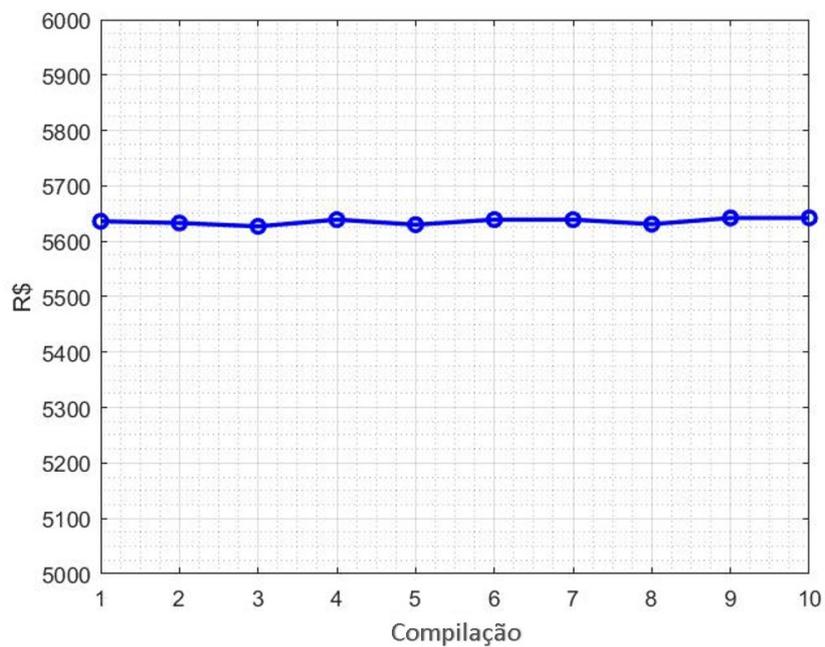
Fonte: Autoria Própria

Figura 112 – Consistência do evolução diferencial para o mês de julho



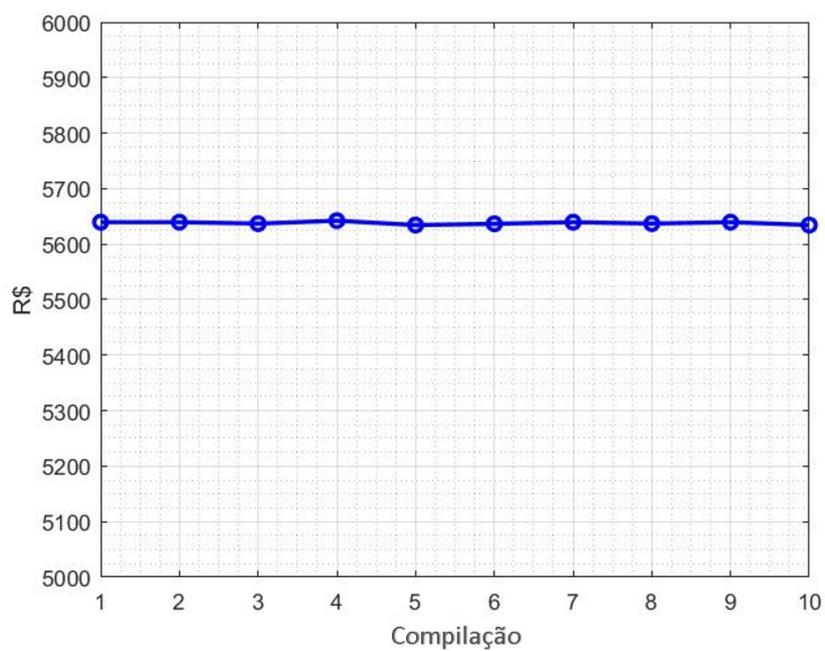
Fonte: Autoria Própria

Figura 113 – Consistência do evolução diferencial para o mês de agosto



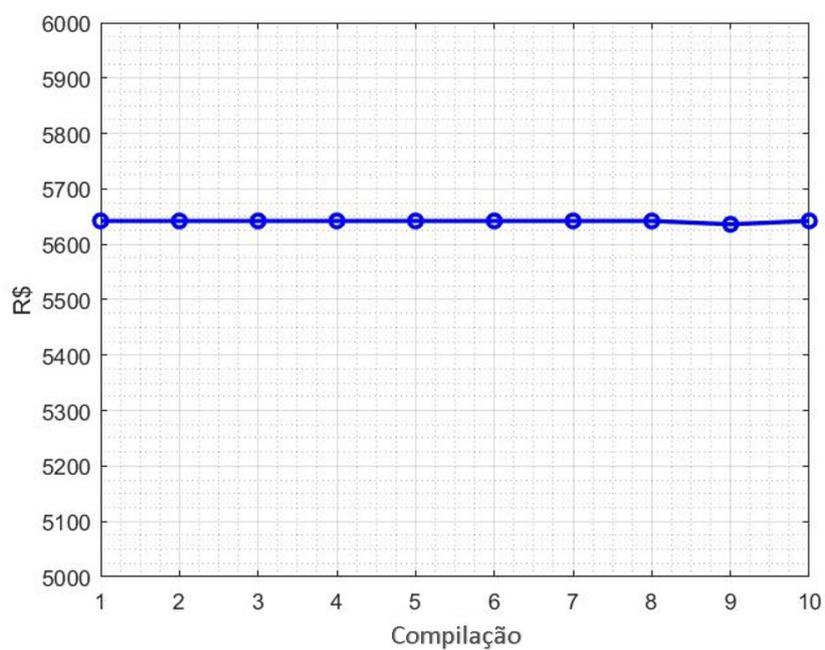
Fonte: Autoria Própria

Figura 114 – Consistência do evolução diferencial para o mês de setembro



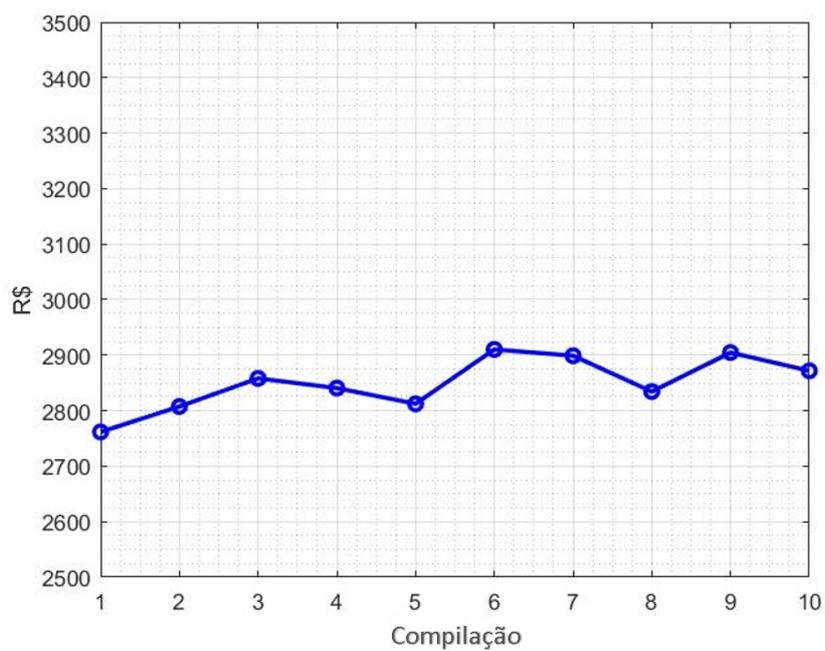
Fonte: Autoria Própria

Figura 115 – Consistência do evolução diferencial para o mês de outubro



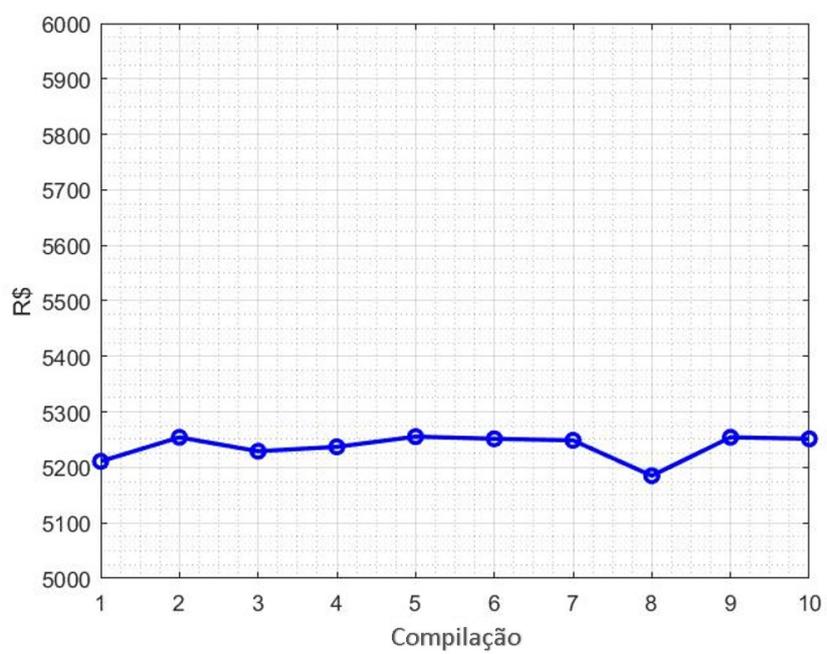
Fonte: Autoria Própria

Figura 116 – Consistência do evolução diferencial para o mês de novembro



Fonte: Autoria Própria

Figura 117 – Consistência do evolução diferencial para o mês de dezembro



Fonte: Autoria Própria