

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA
E TECNOLOGIA FLUMINENSE**

**PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS APLICADOS À
ENGENHARIA E GESTÃO**

Anna Julia de Santana Sobrinho

**OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS BINÁRIO
APLICADO AO PROBLEMA DE GERENCIAMENTO DE ENERGIA
EM UM CAMPUS INTELIGENTE**

Campos dos Goytacazes – RJ

2022

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA
E TECNOLOGIA FLUMINENSE**

**PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS APLICADOS À
ENGENHARIA E GESTÃO**

ANNA JULIA DE SANTANA SOBRINHO

**OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS BINÁRIO APLICADO AO
PROBLEMA DE GERENCIAMENTO DE ENERGIA EM UM CAMPUS INTELIGENTE**

Frederico Galaxe Paes
(Orientador)

André Soares Velasco
(Coorientador)

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação do Instituto Federal de Educação, Ciência e Tecnologia Fluminense, no Curso de Mestrado Profissional em Sistemas Aplicados à Engenharia e Gestão (MPSAEG), como parte dos requisitos necessários à obtenção do título de Mestre em Sistemas Aplicados à Engenharia e Gestão.

Campos dos Goytacazes – RJ

2022

Biblioteca Anton Dakitsch
CIP - Catalogação na Publicação

S677o Sobrinho, Anna Julia de Santana
 Otimização por enxame de partículas binário aplicado ao problema de
 gerenciamento de energia em um campus inteligente / Anna Julia de
 Santana Sobrinho - 2022.
 56 f.: il. color.

 Orientador: Frederico Galaxe Paes
 Coorientador: André Soares Velasco

 Dissertação (mestrado) -- Instituto Federal de Educação, Ciência e
 Tecnologia Fluminense, Campus Campos Centro, Curso de Mestrado
 Profissional em Sistemas Aplicados à Engenharia e Gestão, Campos dos
 Goytacazes, RJ, 2022.
 Referências: f. 56.

 1. Otimização. 2. Gerenciamento de Energia. 3. Redes Inteligentes. I.
 Paes, Frederico Galaxe, orient. II. Velasco, André Soares, coorient. III.
 Título.

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
FLUMINENSE
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS APLICADOS À
ENGENHARIA E GESTÃO

Anna Julia de Santana Sobrinho

OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS BINÁRIO APLICADO AO
PROBLEMA DE GERENCIAMENTO DE ENERGIA EM UM CAMPUS INTELIGENTE

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação do Instituto Federal de Educação, Ciência e Tecnologia Fluminense, no Curso de Mestrado Profissional em Sistemas Aplicados à Engenharia e Gestão (MPSAEG), como parte dos requisitos necessários à obtenção do título de Mestre em Sistemas Aplicados à Engenharia e Gestão.

Aprovada em 05 de abril de 2022.

Banca Examinadora:



Frederico Galaxe Paes, D.Sc

Instituto Federal de Educação, Ciência e Tecnologia Fluminense -IFF
(Orientador)



André Soares Velasco, D.Sc

Instituto Federal de Educação, Ciência e Tecnologia Fluminense - IFF
(Coorientador)



Carlos Leonardo Ramos Póvoa, D.Sc

Instituto Federal de Educação, Ciência e Tecnologia Fluminense - IFF



Marcos Costa Roboredo, D.Sc

Universidade Federal Fluminense - UFF

AGRADECIMENTOS

Agradeço a Deus por guiar meu caminho e tornar possível a realização dos meus objetivos por mais que pareçam impossíveis.

Aos meus pais, Viviane e Alcides, por sempre apoiarem e incentivarem a minha educação mesmo nos tempos mais difíceis e por me ajudarem a chegar até aqui.

Ao meu noivo Victor Henrique por me apoiar, ser minha fortaleza, me ouvir e acreditar em mim durante todo esse processo, principalmente quando a ansiedade e insegurança estiveram presentes.

Ao meu orientador Frederico Paes, ao coorientador André Velasco e ao professor Leonardo Póvoa pela contribuição técnica e científica neste projeto e apoio durante o mestrado.

A equipe do Polo de Inovação de Campos dos Goytacazes por fornecer os dados necessários para a realização deste trabalho.

Ao Instituto Federal Fluminense que me permitiu um ensino gratuito e de qualidade do ensino médio até o mestrado.

A todos que de alguma forma contribuíram durante o desenvolvimento desta pesquisa que representa uma parte importante da minha formação.

RESUMO

Com o aumento da demanda global de energia elétrica e a limitação dos recursos se torna indispensável desenvolver estratégias mais sustentáveis de produção e consumo. Nesse contexto, surgem as Redes Inteligentes com o objetivo de aperfeiçoar o Gerenciamento Pelo Lado da Demanda e a eficiência energética e, em conjunto com ferramentas de Resposta à Demanda, como as tarifas de Tempo-de-Uso, podem reduzir a demanda em períodos críticos e ser um benefício para o consumidor. Porém, devido à complexidade, muitos consumidores acabam não aderindo a essa tarifa, sendo necessário a aplicação de sistemas de gerenciamento de energia inteligente para tirar o máximo de proveito dessa prática. O objetivo deste trabalho é estabelecer um referencial teórico sobre o uso de algoritmos bio-inspirados nesses sistemas e criar a modelagem de um campus inteligente para realizar o gerenciamento dos seus dispositivos utilizando a Otimização por Enxame de Partículas Binário. Este trabalho está estruturado em dois artigos: o primeiro artigo é uma revisão sistemática onde foram encontrados os principais objetivos e modelos utilizados para criação desse sistema, as simulações realizadas, classificação dos dispositivos e os algoritmos utilizados; o segundo artigo é um estudo de caso onde foi implementada a metaheurística no modelo proposto e foram realizados testes em relação aos parâmetros e ao seu comportamento de acordo com o nível de conforto do usuário. Com a devida parametrização o algoritmo realiza a minimização do consumo e da demanda em horários de pico, mas sem causar desconforto considerável ao usuário, auxiliando na sua aderência a programas de resposta à demanda.

Palavras-chave: Otimização, Gerenciamento de Energia, Redes Inteligentes.

ABSTRACT

With the increase in the global demand for electric energy and the limitation of resources, it becomes essential to develop more sustainable strategies for production and consumption. In this context, Smart Grids emerge with the objective of improving Demand-Side Management and energy efficiency and, with Demand Response tools, such as Time-of-Use tariffs, can reduce demand in critical periods and be a benefit to the consumer. However, due its complexity, many consumers end up not adhering to this tariff, requiring the use of intelligent energy management systems to take full advantage of this practice. The objective of this work is to establish a theoretical framework on the use of bio-inspired algorithms in these systems and create the modeling of a smart campus to manage its devices using Binary Particle Swarm Optimization. This work is structured in two articles: the first article is a systematic review where the main objectives and models used to create this system, the simulations performed, classification of devices and the algorithms used were found; the second article is a case study where the metaheuristic was implemented in the proposed model and tests were carried out in relation to the parameters and their behavior according to the user's comfort level. With proper parameterization, the algorithm minimizes consumption and demand at peak times, but without causing considerable discomfort to the user, helping to adhere to demand response programs.

Keywords: Optimization, Energy Management, Smart Grid.

LISTAS

Lista de ilustrações

Figura 1 - Fluxograma de seleção de artigos	16
Figura 2 - Comparação entre as tarifas de energia	31
Figura 3 - Representação vetorial do comportamento das partículas	37
Figura 4 - Consumo de energia do Bloco B do PICG	42
Figura 5 - Geração de energia do PICCG	42
Figura 6 - Convergência do BPSO com 5 partículas	44
Figura 7 - Convergência do BPSO para 80 partículas	44
Figura 8 - Boxplot dos melhores custos para cada nível de conforto	45
Figura 9 - Gráficos de consumo de energia horário para cada resultado	47
Figura 10 - Agendamento dos dispositivos para o nível de conforto 0.5	48
Figura 11 - Agendamento dos dispositivos para o nível de conforto 0.8	48
Figura 12 - Agendamento dos dispositivos pelo BPSO	51
Figura 13 - Agendamento dos dispositivos pelo CPLEX	52

Lista de quadros

Quadro 1 - Termos utilizados na busca	15
Quadro 2 - Pesquisa realizada no Scopus	15
Quadro 3 - Relação dos trabalhos selecionados	17
Quadro 4 - Relação dos fatores analisados	21

Lista de tabelas

Tabela 1 - Amostra de dispositivos do Bloco B do PICG e suas características	30
Tabela 2 – Instâncias para comparação	41
Tabela 3 - Média e desvio padrão do teste de parametrização	43
Tabela 4 - Melhor resultado para cada nível de conforto	45
Tabela 5 - Melhor solução obtida com o BPSO e com o CPLEX	49
Tabela 6 - Gaps percentuais para a função objetivo e para a função consumo	50
Tabela 7 - Tempo de execução utilizando a biblioteca Numba	51
Tabela 8 – Dispositivos da instância 2 e suas características	51

Listas de siglas

BBO – Biogeography-Based Optimization
BPSO – Binary Particle Swarm Optimization
BSOA – Backtracking Search Optimization Algorithm
CPP – Critical Peak-Pricing
CS – Cuckoo Search
DE – Differential Evolution
DR – Demand Response
EC – Evolutionary Computing
EDE – Enhanced Differential Evolution
EDTLA – Enhanced Differential Teaching Learning Algorithm (EDTLA)
FA – Firefly Algorithm
GA – Genetic Algorithm
GBBO – Genetic Biogeography-Based Optimization
GLD – Gerenciamento Pelo Lado da Demanda
GMP – *Gap* Médio Percentual
GWO – Gray Wolf Optimization
HEMS – Home Energy Management System
HGWDE – Hybrid Gray Wolf Differential Evolution
IDE – Integrated Development Environment
JIT – Just-in-Time
MGP – Menor *Gap* Percentual
micro-CHP – micro Combined Heat and Power
PICG – Polo de Inovação de Campos dos Goytacazes
PLI – Programação Linear Inteira
PRISMA – Preferred Reporting Items for Systematic Reviews and Meta-Analyses
PSO – Particle Swarm Optimization
RTP – Real-Time Pricing
SG – Smart Grid
SI – Swarm Intelligence
Spyder – The Scientific Python Development Environment
TBSO – Tabu Backtracking Search Optimization
TLBO – Teaching Learning Based Optimization
ToU – Time-of-Use
TS – Tabu Search

SUMÁRIO

1	APRESENTAÇÃO.....	10
2	ARTIGO 1 – ALGORITMOS BIO-INSPIRADOS PARA OTIMIZAÇÃO DO GERENCIAMENTO DE ENERGIA EM CASAS INTELIGENTES: UMA REVISÃO SISTEMÁTICA.....	12
2.1	Resumo	12
2.2	Abstract.....	12
2.3	Introdução	13
2.4	Metodologia	14
2.5	Resultados e discussão.....	16
2.5.1	Objetivos e simulações.....	18
2.5.2	Técnicas de otimização e visão geral.....	19
2.6	Considerações finais	22
2.7	Referências.....	23
3	ARTIGO 2 - OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS BINÁRIO APLICADO NO GERENCIAMENTO DE ENERGIA: UM ESTUDO DE CASO EM UM CAMPUS INTELIGENTE	26
3.1	Resumo	26
3.2	Abstract.....	27
3.3	Introdução	27
3.4	Metodologia	29
3.4.1	Coleta de dados	29
3.4.1.1	Tarifa de energia	30
3.4.1.2	Geração distribuída e medidores inteligentes	31
3.4.2	Modelagem do sistema.....	32
3.4.2.1	Função consumo	32
3.4.2.2	Função conforto	33
3.4.2.3	Função restrição	33
3.4.2.4	Função objetivo.....	35

3.4.3	Otimização por Enxame de Partículas (PSO)	36
3.4.3.1	PSO Binário	37
3.4.4	Agendamento dos dispositivos.....	38
3.4.5	Parametrização do BPSO	40
3.4.6	Avaliação do BPSO frente ao CPLEX.....	41
3.5	Resultados e discussão	41
3.5.1	Comparação entre tamanhos de população	43
3.5.2	Comparação entre os níveis de conforto	45
3.5.3	Comparação com o CPLEX	49
3.6	Considerações finais	52
3.7	Referências.....	53
	REFERÊNCIAS	56

1 APRESENTAÇÃO

Com o aumento global da demanda de energia elétrica e a limitação dos recursos naturais há uma necessidade cada vez maior de desenvolver estratégias mais sustentáveis através de métodos adequados de produção e consumo de energia. Nesse contexto surgem as Redes Inteligentes (SG do inglês *Smart Grids*) que começaram através da ideia de uma infraestrutura avançada de medição com o objetivo de aperfeiçoar o gerenciamento pelo lado da demanda e a eficiência energética, e são um aprimoramento da rede de energia fornecendo um fluxo bidirecional de eletricidade e informação (FANG et al., 2012).

O Gerenciamento pelo Lado da Demanda (GLD) é o planejamento, implementação e monitoramento de atividades que influenciam o consumo de eletricidade do cliente produzindo uma mudança na curva de demanda. Como o GLD destaca as necessidades dos clientes, é preciso compreender de forma mais detalhada os fatores que influenciam as suas preferências. (GELLINGS, 1985)

A Resposta à Demanda (DR) são técnicas de gerenciamento da demanda do consumidor em resposta a condições de fornecimento de energia e pode ser de dois tipos: resposta à demanda baseada em incentivo, onde é oferecido algum tipo de premiação ou incentivo ao cliente para que reduza sua demanda em períodos de estresse ou necessidade do sistema; e tarifas baseadas no tempo, onde a resposta a demanda do cliente é baseada em sinais de preço e incluem tarifas de tempo-de-uso (ToU, do inglês *Time-of-Use*), preços de pico críticos (CPP do inglês *Critical Peak-Pricing*) e preços em tempo-real (RTP do inglês *Real-Time Pricing*). (GELLINGS, 2013)

No Brasil, a tarifa do tipo ToU é a Tarifa Horária Branca aprovada em 2016 pela Agência Nacional de Energia Elétrica (ANEEL, 2016) que possui três postos tarifários: ponta, intermediário e fora de ponta. O posto tarifário fora de ponta dura muitas horas e tem um custo menor que o da tarifa convencional e os demais postos duram poucas horas e tem um custo maior (ANEEL, 2020). Com isso, os consumidores são compensados pela menor demanda nos horários críticos, mas caso não consigam deslocar o consumo para fora desse período pode ocasionar em um aumento indesejável na conta de luz.

Casas, prédios e outras estruturas inteligentes são essenciais para melhor aproveitamento dessas redes, pois contém sensores e comunicação entre dispositivos permitindo um rastreamento da energia em tempo real, controle de dispositivos, medidores inteligentes. Com isso, é possível implementar os sistemas de gerenciamento de energia inteligentes que são ferramentas de DR que aperfeiçoam a produção e o consumo de energia

realizando um planejamento ótimo das cargas. Para realizar esse agendamento três abordagens são geralmente utilizadas: otimização matemática, buscas metaheurísticas e métodos heurísticos (BEAUDIN; ZAREIPOUR, 2015).

Em um campus inteligente, o qual foi considerado neste trabalho, o agendamento de dispositivos para se adequar a uma tarifa ToU deve considerar um grande número de parâmetros, como a características das cargas, os diferentes horários de funcionamento de acordo com a funcionalidade do ambiente, os diferentes padrões comportamentais dos consumidores que trabalham no local e a geração de energia renovável, tornando o sistema ainda mais complexo. Com isso, se torna necessário uma melhor análise das técnicas de otimização comumente utilizadas e realizar a modelagem adequada do sistema de forma a maximizar os benefícios da implementação de programas de DR e atender o conforto dos consumidores.

Este trabalho apresenta dois artigos, sendo que o primeiro foi publicado no XXIV Encontro Nacional de Modelagem Computacional em outubro de 2021 e visou analisar sistematicamente a utilização de algoritmos bio-inspirados na otimização do gerenciamento de energia em residências inteligentes. Neste artigo foi utilizado a base Scopus e a metodologia PRISMA para selecionar estudos relacionados ao tema. Esta análise permitiu observar que os principais objetivos desse problema de otimização, as tarifas de energia utilizadas e classificação dos dispositivos na modelagem do sistema. Além disso, foi observado também os algoritmos utilizados e as lacunas dessa área.

O segundo artigo busca aplicar um algoritmo de Otimização por Enxame de Partículas Binário para realizar o gerenciamento de energia de acordo com o nível de conforto definido pelo usuário e utiliza o campus inteligente do Instituto Federal Fluminense, o Polo de Inovação de Campos dos Goytacazes (PICG), como base para desenvolver a modelagem do sistema. Foram utilizados dados de consumo e geração de energia do PICG, um levantamento dos dados dos dispositivos agendáveis e a linguagem de programação Python no software Spyder para criar o algoritmo que realizou o agendamento dos dispositivos. Foi observado o comportamento do algoritmo frente a variações paramétricas e a partir da parametrização foram realizados testes para diferentes níveis de conforto do usuário. Esses testes permitiram encontrar os melhores valores para os parâmetros e o nível de conforto mais indicado para encontrar um equilíbrio entre redução de consumo de energia, principalmente em horários críticos e maximização do conforto do usuário que é um ponto importante na sua aderência em programas que visam o gerenciamento pelo lado da demanda. Foi observado também o desempenho do algoritmo frente ao software comercial IBM ILOG CPLEX na linguagem Pyomo.

2 ARTIGO 1 – ALGORITMOS BIO-INSPIRADOS PARA OTIMIZAÇÃO DO GERENCIAMENTO DE ENERGIA EM CASAS INTELIGENTES: UMA REVISÃO SISTEMÁTICA

2.1 Resumo

Contexto: Com a evolução do conceito de redes inteligentes, diversos métodos para aumentar a eficiência energética e a resposta à demanda vem sendo desenvolvidos, dentre eles os sistemas de gerenciamento de energia residencial. Uma das abordagens para gerenciar de forma inteligente esses sistemas é a computação bio-inspirada.

Objetivo: O objetivo deste estudo é realizar uma revisão sistemática sobre a utilização de algoritmos bio-inspirados na otimização do gerenciamento de energia em casas inteligentes para identificar as técnicas utilizadas e os modelos em que são aplicados.

Metodologia: A busca de artigos foi realizada na base Scopus e foi adotada a metodologia PRISMA para selecionar os estudos mais aderentes ao tema.

Resultados: Foram identificados 50 relatos e após a aplicação dos critérios de seleção e elegibilidade foram selecionados 9 artigos.

Conclusão: Concluiu-se que os modelos mais utilizados têm como principais objetivos a minimização do custo e da razão pico-média e maximização do conforto. As simulações consideram tarifas de energia variáveis no tempo e geralmente apresentam residências com diferentes tipos de dispositivos. Em relação a técnica concluiu-se que há uma variedade de algoritmos utilizados para esse propósito e os híbridos tem um grande potencial. Outro fator observado foi que há uma compensação entre o conforto e o consumo.

Palavras-chave: Algoritmos Evolutivos; Inteligência de Enxame; HEMS; Smart Grid; Smart Home.

2.2 Abstract

Context: With the smart grids concept evolution, several methods to increase energy efficiency and response demand have been developed, including home energy management systems. One of the approaches to intelligently managing these systems is bio-inspired computing.

Objective: The aim of this study is to carry out a systematic review on bio-inspired optimization algorithms in smart homes energy management to identify the techniques used and the models in which they are applied.

Methodology: The search for articles was carried out in the Scopus database and the PRISMA methodology was adopted to select the studies that most adhered to the topic.

Results: Fifty reports were identified and after applying the selection and eligibility criteria, nine articles were selected.

Conclusion: It was concluded that the most used models have as main objectives the minimization of the cost and the peak to average ratio and the maximization of comfort. The simulations consider time-varying energy tariffs and typically presents homes with different types of devices. Regarding the techniques, it was concluded that there is a variety of algorithms used for this purpose and hybrids have a great potential. Another factor observed was that there is a trade-off between comfort and consumption.

Keywords: Evolutionary Algorithms; Swarm Intelligence; HEMS; Smart Grid; Smart Home.

2.3 Introdução

Com a evolução do conceito de redes inteligentes (*Smart Grids*) diversos métodos vêm sendo desenvolvidos para aumentar a eficiência energética. A resposta à demanda (DR do inglês *Demand Response*) é considerada a solução com maior custo-benefício para diminuir a curva de demanda quando o sistema está sob estresse. São considerados como DR qualquer procedimento aplicado para motivar mudanças nos hábitos dos consumidores em resposta a incentivos relacionados ao custo da energia (VARDAKAS *et al.*, 2015).

O *Home Energy Management System* (HEMS), sistema de gerenciamento de energia residencial, é uma ferramenta de DR que ajusta a demanda a fim de melhorar o consumo de energia e os hábitos de consumo da residência de acordo com o custo tarifário da eletricidade e o conforto do usuário. Esse sistema encontra o agendamento adequado dos dispositivos da casa utilizando um algoritmo e as abordagens mais utilizadas são a otimização matemática, buscas metaheurísticas e métodos heurísticos, sendo as duas últimas as mais utilizadas por requererem menos esforço computacional (BEAUDIN; ZAREIPOUR, 2015).

O sistema de gerenciamento de energia inteligente é aplicado em casas, prédios ou redes inteligentes e pode incluir fontes de energia tradicionais e renováveis, além de ter diversos objetivos como a demanda de energia, o custo da eletricidade, a razão pico-média, o conforto do usuário, custos de operação e emissões de carbono. Para gerenciar de forma inteligente essas informações uma das abordagens é a utilização de computação bio-inspirada que são métodos

baseados nos conceitos da evolução biológica da natureza para criação de técnicas novas e robustas (NGUYEN *et al.*, 2020).

Esses algoritmos podem ser do tipo Computação Evolutiva (EC do inglês *Evolutionary Computing*) que simulam conceitos evolutivos para resolver problemas de otimização ou do tipo Inteligência de Enxame (SI do inglês *Swarm Intelligence*) que se baseia no comportamento coletivo de diferentes espécies (formigas, abelhas, pássaros, entre outros) e formam um grupo de agentes com princípios básicos de interação. Diversos novos algoritmos bioinspirados vem sendo publicados recentemente para resolver problemas relacionados aos HEMS e esses algoritmos também podem ser hibridizados para reduzir a complexidade e melhorar ainda mais as soluções (NGUYEN *et al.*, 2020).

Os trabalhos nessa área de conhecimento buscam desenvolver as mais diversas técnicas de otimização bioinspirada para diferentes cenários de gerenciamento de carga residenciais. Com isso, torna-se necessário sistematizar essas diferentes técnicas e o modelo dos sistemas em que são aplicados.

Este estudo tem como objetivo realizar uma revisão sistemática sobre a utilização da computação bio-inspirada na otimização do gerenciamento de energia em prédios e casas inteligentes identificando os modelos utilizados em cada trabalho, seus objetivos, restrições, simulações e algoritmos utilizados de forma a buscar um maior entendimento sobre como são aplicadas essas técnicas de otimização nesse tipo de problema.

2.4 Metodologia

A seleção dos artigos desse trabalho foi realizada seguindo a metodologia PRISMA – *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* que é uma diretriz com objetivo de auxiliar autores melhorando os relatos dos dados das pesquisas e orientando na avaliação da revisão de trabalhos já publicados (LIBERATI *et al.*, 2009). A busca pelos artigos foi realizada na plataforma Scopus que contém cerca de 77 milhões de documentos e 16 milhões de autores sendo o maior banco de dados de resumos e citações da literatura revisada (ELSEVIER, 2020).

As palavras-chave utilizadas foram Otimização (*Optimization*), Algoritmos Bio-inspirados (*Bio-inspired Algorithm*), Gerenciamento de Energia (*Energy Management*) e Casa Inteligente (*Smart Home*). Seus tesouros foram definidos conforme o Quadro 1.

Foram considerados dois critérios de inclusão: utilização de algoritmos bio-inspirados como técnica de otimização; abordar o gerenciamento do consumo de energia de um prédio ou casa inteligente. Além disso, como critério de exclusão, foram considerados artigos de revisão de conferência por não apresentarem informações completas e artigos de revisão de literatura. Os trabalhos elegidos foram lidos por completo para realizar a revisão sendo descartados os que não estavam dentro dos critérios de inclusão.

2.5 Resultados e discussão

A busca resultou em 50 artigos que passaram por uma análise dos títulos e resumos a fim de verificar sua aderência ao tema, sendo que somente 26 estavam de acordo com os critérios e, desses, 14 foram elegidos para serem lidos por completo. Após a leitura completa dos textos foram incluídos 9 artigos. A Figura 1 apresenta a estratégia de busca e seleção utilizada.

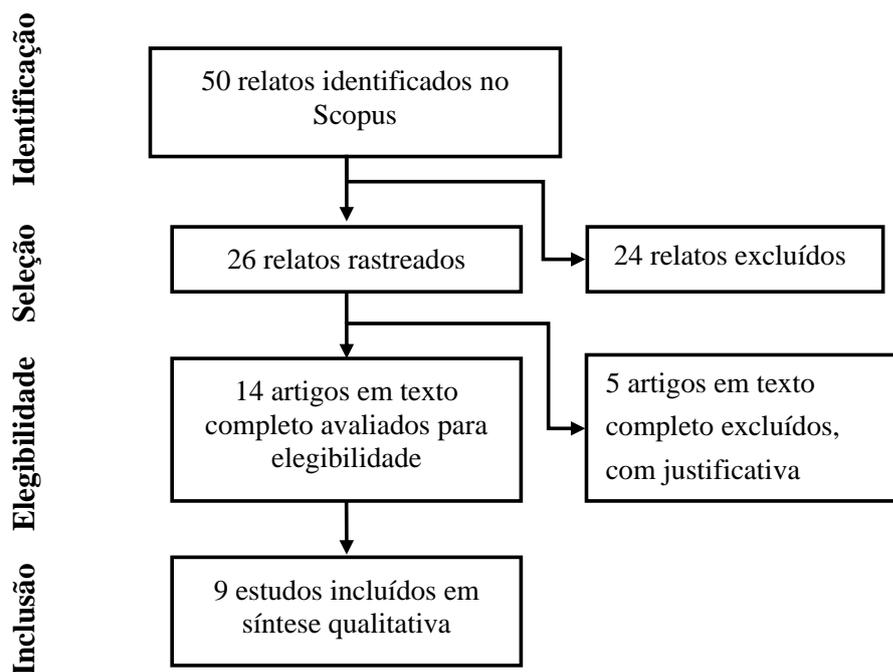


Figura 1 - Fluxograma de seleção de artigos

Fonte: Autora (2022)

No Quadro 3 é apresentada uma síntese com os nove artigos selecionados, onde é possível constatar que nos últimos cinco anos tem crescido o número de publicações referente ao uso de algoritmos bio-inspirados em sistemas de gerenciamento de cargas em casas inteligentes, sendo 2018 o ano com mais publicações.

Quadro 3 - Relação dos trabalhos selecionados

Nº	Título	Autores	Ano	Veículo
1	An Intelligent Load Management System with Renewable Energy Integration for Smart Homes	JAVAID <i>et al.</i>	2017	IEEE Access
2	A Hybrid PSO-DE Algorithm for Smart Home Energy Management	HUANG <i>et al.</i>	2014	Lecture Notes in Computer Science
3	An Efficient Scheduling of Electrical Appliance in Micro Grid Based on Heuristic Techniques	HUSSAIN <i>et al.</i>	2018	Advances in Intelligent Systems and Computing
4	Swarm Intelligence Based Home Energy Management Controller Under Dynamic Pricing Scheme	AHMED <i>et al.</i>	2018	Lecture Notes on Data Engineering and Communications Technologies
5	An approach towards efficient scheduling of home energy management system using backtracking search optimization and tabu search	SHAFIQ <i>et al.</i>	2018	Proceedings - 32nd IEEE International Conference on Advanced Information Networking and Applications Workshops, WAINA 2018
6	Improving Energy Efficiency in Smart-Houses by Optimizing Electrical Loads Management	CABRITA <i>et al.</i>	2019	SyNERGY MED 2019 - 1st International Conference on Energy Transition in the Mediterranean Area
7	Efficient Power Scheduling in Smart Homes using Meta Heuristic Hybrid Grey Wolf Differential Evolution Optimization Technique	NAZ <i>et al.</i>	2018	Proceedings - International Conference on Advanced Information Networking and Applications, AINA 2018
8	Differential Evolution based Energy Management System for Zero Net Energy Building	MADATHIL <i>et al.</i>	2018	Proceedings of 2017 IEEE International Conference on Technological Advancements in Power and Energy: Exploring Energy Solutions for an Intelligent Power Grid, TAP Energy 2017
9	Home Energy Management in Smart Grid using Evolutionary Algorithms	SABOOR <i>et al.</i>	2018	Proceedings - International Conference on Advanced Information Networking and Applications, AINA 2018

Fonte: Autora (2022)

2.5.1 Objetivos e simulações

Em JAVAID *et al.* (2016), HUSSAIN *et al.* (2018), AHMED *et al.* (2018), SHAFIQ *et al.* (2018), NAZ *et al.* (2018) e SABOOR *et al.* (2018) os objetivos são a minimização do consumo de energia, a minimização da razão pico-média e a maximização do conforto que é o tempo de espera para ligar e desligar as cargas a partir dos horários definidos.

Foi identificado nesses estudos que as simulações geralmente consideram uma ou mais casas inteligentes ou um prédio inteligente que podem contar com fontes de energia renovável, baterias e geradores. Os dispositivos podem ser separados em cargas fixas (ou base ou inflexíveis) que não podem sofrer alterações, cargas interrompíveis (ou controladas) que podem ser interrompidas sem alterar o tempo de duração e cargas não interrompíveis que uma vez acionados não podem ser interrompidos. Além dessas especificações todos os trabalhos utilizam tarifas de preço de energia variáveis no tempo.

Entre os estudos que apresentam objetivos um pouco diferentes estão HUANG *et al.* (2014) que buscam não somente a minimização do custo com energia, mas também a minimização do consumo de gás pela unidade micro-CHP (*micro Combined Heat and Power*). A simulação conta com dispositivos elétricos fixos, dispositivos térmicos agendáveis, baterias e fonte de energia renovável. Com isso, também é acrescentado em suas restrições a temperatura do prédio e a água quente requerida de acordo com os dados de temperatura interna e externa para garantir um nível de conforto e as restrições de operação da unidade e da carga e descarga da bateria.

CABRITA *et al.* (2019) também tem alguns objetivos além da redução de custo que envolvem os parâmetros do algoritmo utilizado. Para isso realiza primeiro duas simulações, uma com 25 e outra com 50 dispositivos, sem restrição de tempo para encontrar os valores dos parâmetros do algoritmo que apresentam o melhor resultado. Em seguida, com esses parâmetros são realizadas duas simulações, uma com 29 e outra com 54 dispositivos, com restrição de tempo para analisar a influência do número de cargas, tamanho da população e número de gerações.

Diferente dos demais que buscam o menor custo possível com energia, MADATHIL *et al.* (2017) tem como objetivo reduzir o consumo a zero a fim de diminuir as emissões de carbono e garantir a autonomia energética em um prédio. Para isso realiza a simulação em um prédio com nove dispositivos e fonte de energia renovável onde o somatório de cargas geradas e consumidas deve ser igual a zero.

2.5.2 Técnicas de otimização e visão geral

JAVOID *et al.* (2016) utilizam as técnicas *Binary Particle Swarm Optimization* (BPSO), *Genetic Algorithm* (GA) e *Cuckoo Search* (CS) e os resultados mostram que todos os algoritmos apresentam uma redução considerável do custo de eletricidade e dos picos de potência, sendo que o CS apresenta o melhor resultado em comparação com o GA e o BPSO. Além disso, o estudo também analisa três casos: casas tradicionais sem sistema HEM, casas inteligentes e casas inteligentes com energia renovável e baterias. Os autores concluem que casas tradicionais tem um custo maior pela mesma energia utilizada em casas inteligentes, porém o nível de conforto também é maior e casas inteligentes com energia renovável tem o menor custo de eletricidade e o menor conforto.

HUANG *et al.* (2014) propõem um algoritmo híbrido unindo o *Particle Swarm Optimization* (PSO) com o *Differential Evolution* (DE) formando o PSO-DE. O híbrido consegue atingir resultados ótimos dentro das restrições comprando o mínimo de energia durante os horários de pico e vendendo a energia excedente para a concessionária em horários fora de pico.

HUSSAIN *et al.* (2018) comparam técnicas existentes como *Genetic Algorithm* (GA), *Teaching Learning Based Optimization* (TLBO) e *Enhanced Differential Evolution* (EDE) com seu novo algoritmo híbrido *Enhanced Differential Teaching Learning Algorithm* (EDTLA). Todos os algoritmos tem capacidade de encontrar o objetivo em cenários similares e as simulações provam a aplicabilidade e validação do novo algoritmo proposto em termos de redução de custo e da razão pico-média, mas não tem melhores resultados em relação a maximização de conforto.

Em AHMED *et al.* (2018) foram utilizados os algoritmos já existentes BPSO e *Firefly Algorithm* (FA) e como resultado o FA tem a melhor performance em relação a minimização do custo e da razão pico-média enquanto maximiza o conforto do usuário.

SHAFIQ *et al.* (2018) utilizam as técnicas *Backtracking Search Optimization Algorithm* (BSOA), *Tabu Search* (TS) e o híbrido *Tabu Backtracking Search Optimization* (TBSO). Todas as técnicas apresentam uma considerável redução do custo e da razão pico-média. O TBSO apresenta a melhor performance em relação ao custo, porém a pior em relação ao conforto. O melhor algoritmo para obter um equilíbrio entre redução de custo e maximização de conforto é o BSOA.

Diferente dos demais artigos, CABRITA *et al.* (2019) não propõem um novo algoritmo e nem compara as técnicas entre si, mas explora os parâmetros e a estrutura do GA para apresentar

a importância do processo de sintonização paramétrica das heurísticas, principalmente quando há uma grande quantidade de restrições no sistema. Nas simulações fica claro o quanto esse fator é decisivo na performance final do algoritmo, pois em alguns casos as combinações testadas tiveram um resultado inaceitável. Os autores também concluem que no GA a complexidade computacional é pouco afetada pelo número de cargas e depende mais do número de gerações e tamanho da população.

NAZ *et al.* (2018) comparam as técnicas EDE e *Gray Wolf Optimization* (GWO) com o híbrido proposto por eles chamado *Hybrid Gray Wolf Differential Evolution* (HGWDE). Os resultados mostram que o HGWDE supera as outras técnicas em todos os aspectos menos no tempo de espera. Com isso, novamente é visto que há uma compensação entre custo e conforto.

MADATHIL *et al.* (2017) utilizam o algoritmo DE para dois valores diferentes no parâmetro taxa de cruzamento e com a alteração encontra o melhor o resultado que mantém um consumo zero no prédio.

Em SABOOR *et al.* (2018) são comparadas as técnicas GA, *Biogeography-Based Optimization* (BBO) e o híbrido proposto *Genetic Biogeography-Based Optimization* (GBBO). O BBO encontra um melhor resultado em relação ao conforto e tem uma redução da razão pico-média e o GBBO proposto supera as outras técnicas em relação a redução do custo e a razão pico-média.

Como visto em NGUYEN *et al.* (2020) há uma grande variedade de algoritmos bio-inspirados sendo utilizados em HEMS e os algoritmos híbridos são a maioria nesse estudo e que apresentam o melhor resultado em relação a minimização do custo da energia.

Nos estudos que levam em conta o conforto do usuário é visto pelos autores que há uma compensação entre o conforto e o consumo, pois quanto menor o custo com eletricidade menor o nível de conforto do usuário. Com isso, o melhor algoritmo acaba não sendo o que apresenta como resultado o menor custo de energia e sim o que apresenta um equilíbrio entre o consumo e conforto do usuário.

Seguindo a ordem de identificação dos artigos no Quadro 3 foi elaborado o Quadro 4 que apresenta uma visão geral dos fatores analisados: algoritmos utilizados, tarifa de energia, os objetivos de cada estudo, as simulações realizadas, detalhes considerados como restrições e a tarifa de energia utilizada.

Quadro 4 - Relação dos fatores analisados

Nº	Algoritmos	Tarifa	Objetivos	Simulação	Detalhes
1	BPSO GA CS	ToU	Minimizar o consumo; Minimizar a razão pico-média; Maximização do conforto.	Casas tradicionais sem HEM; Casas inteligentes; Casas inteligentes com energia renovável e baterias; 6 dispositivos.	Carga base; Carga interrompível; Tempo de operação dos dispositivos.
2	PSO-DE	ToU	Minimizar o custo de energia; Minimizar o custo de gás consumido pela unidade micro-CHP; Não violar as restrições.	Uma casa inteligente; Unidade micro-CHP; Baterias; Fonte de Energia Renovável.	Dispositivos elétricos fixos; Dispositivos térmicos agendáveis; Restrições de carga e descarga da bateria; Restrições de água quente e temperatura do prédio requerida; Restrições de operação da unidade micro-CHP.
3	GA TLBO EDE EDTLA	RTP	Minimizar o consumo; Minimizar a razão pico-média; Maximização do conforto.	1 prédio inteligente com 30 casas; 12 dispositivos inteligentes em cada casa.	Horário mínimo e máximo para inicializar e finalizar a operação de cada dispositivo; Dispositivos inflexíveis; Dispositivos flexíveis.
4	BPSO FA	RTP	Minimizar o consumo; Minimizar a razão pico-média; Maximização do conforto.	1 casa inteligente; 3 dispositivos individualmente; Cada dispositivo é testado para 2 níveis de prioridade diferente.	Cada dispositivo tem uma flexibilidade diferente em relação ao escalonamento.
5	BSOA TS TBSO	RTP	Minimizar o consumo; Minimizar a razão pico-média; Maximização do conforto.	1 casa inteligente com 9 dispositivos; Fontes de energia renovável; Baterias e geradores.	Dispositivos fixos; Dispositivos deslocáveis.
6	GA	ToU	Minimizar o consumo; Redução do pico de carga; Encontrar os parâmetros que	Fonte de energia renovável; Agendamento sem restrição de tempo com diferentes parâmetros para 25 e 50 dispositivos;	Restrição de potência máxima; Restrição do período em que cada dispositivo pode ser alocado.

			apresentam o melhor resultado; Analisar a influência de cada parâmetro no resultado.	Agendamento com restrição de tempo e com o melhor parâmetro para 29 e 54 dispositivos.	
7	HGWDE	RTP	Minimizar o consumo; Minimizar a razão pico-média; Maximização do conforto.	1 casa inteligente; 17 dispositivos.	Dispositivos deslocáveis não interrompíveis; Dispositivos controlados; Dispositivos não deslocáveis.
8	DE	RTP	Reduzir o consumo a zero; Reduzir emissões de carbono.	1 prédio; 9 dispositivos; Fonte de energia renovável; Agendamento sem restrições; Agendamento com restrições e alteração da taxa de cruzamento do DE.	Somatório de cargas geradas e consumidas igual a zero; Tempo de operação da máquina de lavar-roupas e da lava-louças.
9	GA BBO GBBO	ToU	Minimizar o consumo; Minimizar a razão pico-média; Maximização do conforto.	8 dispositivos por casa; Agendamento de uma casa em diferentes intervalos de tempo; Agendamento de 10, 30 e 50 casas pelo mesmo intervalo de tempo.	Dispositivos base; Dispositivos interrompíveis; Dispositivos não interrompíveis.

Fonte: Autora (2022)

2.6 Considerações finais

O objetivo principal deste trabalho foi realizar uma revisão sistemática sobre a utilização de computação bio-inspiradas na otimização do gerenciamento de energia em residências inteligentes a fim de identificar como esses algoritmos são aplicados em HEMS e os diferentes modelos de sistema em que são utilizadas.

Como resultado foram encontrados 50 relatos na base Scopus e desses foram selecionados 9 artigos mais aderentes ao tema.

Em relação aos modelos dos sistemas foi visto que a maior parte dos estudos tem como objetivo a minimização do custo com energia e da razão pico-média e a maximização do

conforto. As simulações consideram tarifas de energia variáveis no tempo e em geral apresentam uma ou mais casas inteligentes ou um prédio inteligente que contém dispositivos classificados em fixos, interrompíveis e não interrompíveis.

Em relação a técnica de otimização observou-se uma variedade de algoritmos e um grande potencial dos algoritmos híbridos que são mais recentes e vem crescendo nessa área.

Outro fator observado foi que há uma compensação entre o conforto e o consumo e com isso dependendo do foco do trabalho o melhor algoritmo pode não ser o que apresenta o menor custo com energia e sim o que encontra um equilíbrio entre conforto e consumo.

Para trabalho futuros, recomenda-se a expansão da busca dessa revisão para outras bases de dados além do Scopus e a inclusão de outros conceitos ou tesouros para ampliar o estudo para o gerenciamento de cargas industriais e comerciais.

2.7 Referências

AHMED, A. et al. Swarm Intelligence Based Home Energy Management Controller Under Dynamic Pricing Scheme. In: BAROLLI, L.; XHAFA, F.; CONESA, J. (Eds.). . **Advances on Broad-Band Wireless Computing, Communication and Applications**. Lecture Notes on Data Engineering and Communications Technologies. Cham: Springer International Publishing, 2018. v. 12p. 256–266.

BEAUDIN, M.; ZAREIPOUR, H. Home energy management systems: A review of modelling and complexity. **Renewable and Sustainable Energy Reviews**, v. 45, p. 318–335, maio 2015.

CABRITA, C. L.; MONTEIRO, J. M.; S. CARDOSO, P. J. Improving Energy Efficiency in Smart-Houses by Optimizing Electrical Loads Management. 2019 1st International Conference on Energy Transition in the Mediterranean Area (SyNERGY MED). **Anais...** In: 2019 1ST INTERNATIONAL CONFERENCE ON ENERGY TRANSITION IN THE MEDITERRANEAN AREA (SYNERGY MED). maio 2019.

ELSEVIER. **Scopus - Content Coverage Guide**. [s.l: s.n.]. Disponível em: <<https://www.elsevier.com/?a=69451>>. Acesso em: 7 maio. 2020.

HUANG, Y.; WANG, L.; WU, Q. A Hybrid PSO-DE Algorithm for Smart Home Energy Management. In: TAN, Y.; SHI, Y.; COELLO, C. A. C. (Eds.). . **Advances in Swarm Intelligence**. Lecture Notes in Computer Science. Cham: Springer International Publishing, 2014. v. 8795p. 292–300.

HUSSAIN, S. M. et al. An Efficient Scheduling of Electrical Appliance in Micro Grid Based on Heuristic Techniques. In: BAROLLI, L.; TERZO, O. (Eds.). . **Complex, Intelligent, and Software Intensive Systems**. Advances in Intelligent Systems and Computing. Cham: Springer International Publishing, 2018. v. 611p. 164–173.

JAVAID, N. et al. An Intelligent Load Management System with Renewable Energy Integration for Smart Homes. **IEEE Access**, p. 14, 2016.

LIBERATI, A. et al. The PRISMA Statement for Reporting Systematic Reviews and Meta-Analyses of Studies That Evaluate Health Care Interventions: Explanation and Elaboration. **PLOS Medicine**, v. 6, n. 7, p. e1000100, 21 jul. 2009.

MADATHIL, D. et al. Differential evolution based energy management system for zero net energy building. 2017 International Conference on Technological Advancements in Power and Energy (TAP Energy). **Anais...** In: 2017 INTERNATIONAL CONFERENCE ON TECHNOLOGICAL ADVANCEMENTS IN POWER AND ENERGY (TAP ENERGY). Kollam: IEEE, dez. 2017. Disponível em: <<https://ieeexplore.ieee.org/document/8397310/>>. Acesso em: 30 set. 2021

NAZ, M. et al. Efficient Power Scheduling in Smart Homes Using Meta Heuristic Hybrid Grey Wolf Differential Evolution Optimization Technique. 2018 IEEE 32nd International Conference on Advanced Information Networking and Applications (AINA). **Anais...** In: 2018 IEEE 32ND INTERNATIONAL CONFERENCE ON ADVANCED INFORMATION NETWORKING AND APPLICATIONS (AINA). Krakow, Poland: IEEE, maio 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8432300/>>. Acesso em: 30 set. 2021

NGUYEN, T.-H. et al. Bio-Inspired Approaches for Smart Energy Management: State of the Art and Challenges. **Sustainability**, v. 12, n. 20, p. 8495, 15 out. 2020.

SABOOR, A. et al. Home Energy Management in Smart Grid Using Evolutionary Algorithms. 2018 IEEE 32nd International Conference on Advanced Information Networking and Applications (AINA). **Anais...** In: 2018 IEEE 32ND INTERNATIONAL CONFERENCE ON ADVANCED INFORMATION NETWORKING AND APPLICATIONS (AINA). Krakow: IEEE, maio 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8432356/>>. Acesso em: 30 set. 2021

SHAFIQ, S. et al. An Approach Towards Efficient Scheduling of Home Energy Management System Using Backtracking Search Optimization and Tabu Search. 2018 32nd International

Conference on Advanced Information Networking and Applications Workshops (WAINA). **Anais...** In: 2018 32ND INTERNATIONAL CONFERENCE ON ADVANCED INFORMATION NETWORKING AND APPLICATIONS WORKSHOPS (WAINA). Krakow: IEEE, maio 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8418076/>>. Acesso em: 30 set. 2021

VARDAKAS, J. S.; ZORBA, N.; VERIKOUKIS, C. V. A Survey on Demand Response Programs in Smart Grids: Pricing Methods and Optimization Algorithms. **IEEE Communications Surveys and Tutorials**, v. 17, n. 1, p. 152–178, 2015.

3 ARTIGO 2 - OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS BINÁRIO APLICADO NO GERENCIAMENTO DE ENERGIA: UM ESTUDO DE CASO EM UM CAMPUS INTELIGENTE

3.1 Resumo

Contexto: Um sistema de gerenciamento de energia inteligente pode ser aplicado para diversas finalidades, como a redução do custo com eletricidade e a maximização conforto do usuário, e auxilia programas de resposta à demanda. A sua aplicação em sistemas reais pode se tornar um problema muito complexo e a Inteligência de Enxame é uma das técnicas de computação bio-inspirada que podem ser utilizadas nesse problema.

Objetivo: Este trabalho propõe um modelo matemático de um sistema real e complexo, como o Polo de Inovação de Campos dos Goytacazes, considerando suas particularidades e avalia o desempenho da Otimização por Enxame de Partículas Binário no problema de gerenciamento de energia deste cenário.

Metodologia: No estudo de caso é desenvolvida a formulação matemática do problema através de uma função objetivo que busca conciliar o consumo e o conforto do usuário levando em conta as restrições do Polo de Inovação de Campos dos Goytacazes. Foram realizados testes de parametrização e para diferentes níveis de conforto com a Tarifa Horária Branca. Foi realizado também uma comparação com o software CPLEX.

Resultados: Os resultados mostram que uma população de 50 partículas é o mais adequado para o algoritmo e o nível de conforto 0.5 obtém um planejamento adequado para cenários reais, trazendo mais conforto e reduzindo o consumo e a demanda em horários de pico. Quando comparado ao CPLEX, a metaheurística se mostra mais lenta, porém, consegue obter um menor *gap* percentual de 0.0% em duas das quatro instâncias testadas.

Conclusão: O algoritmo é eficiente em gerenciamento dos dispositivos, minimizando o consumo enquanto mantém o nível de conforto desejado, característica importante para a aderência a programas de resposta à demanda, mas precisa ser aperfeiçoado para reduzir seu tempo de execução.

Palavras-chave: BPSO; Sistema de Gerenciamento de Energia; Campus Inteligente.

3.2 Abstract

Context: An intelligent energy management system can be applied for several purposes, such as reducing electricity costs and maximizing user comfort, and supporting demand response programs. Its application in real systems can become a very complex problem and Swarm Intelligence is one of the bio-inspired computing techniques that can be used in this problem.

Objective: This work proposes a mathematical model of a real and complex system, such as the Polo de Inovação de Campos dos Goytacazes, considering its particularities and evaluates the performance of Binary Particle Swarm Optimization in the energy management problem of this scenario.

Methodology: The case study presents the mathematical formulation of the problem through an fitness function that seeks to reconcile consumption and user comfort, taking into account the restrictions of the Polo de Inovação de Campos dos Goytacazes. Tests were made for parameterization and for different levels of comfort with the ToU Tariff. A comparison with the CPLEX software was also performed.

Results: The results show that a population of 50 particles is the most suitable for the algorithm and the comfort level 0.5 obtains a adequate scheduling for real scenarios, bringing more comfort and reducing consumption and demand at peak times. When compared to CPLEX, the metaheuristic is slower, however, it manages to obtain a smaller percentage gap of 0.0% in two of the four tested instances.

Conclusion: The algorithm is efficient in managing the devices, minimizing consumption while maintaining the desired comfort level, an important feature for adherence to demand response programs, but it needs to be improved to reduce its execution time.

Keywords: BPSO; Energy Management Systems; Smart Campus.

3.3 Introdução

Um sistema de gerenciamento de energia inteligente pode ser aplicado em casas, prédios e redes inteligentes, com ou sem energia renovável, a fim de reduzir o custo com eletricidade conciliando com o conforto do usuário e realizando um planejamento do consumo levando em conta diversas restrições e variáveis do sistema. As técnicas de otimização bio-inspirada são uma das formas de realizar esse gerenciamento inteligente. Essas técnicas podem ser do tipo Inteligência de Enxame (SI do inglês *Swarm Intelligence*) se baseando no comportamento

coletivo de espécies e formando um grupo de indivíduos com princípios básicos de iteração (NGUYEN et al., 2020).

A otimização por enxame de partículas (PSO do inglês *Particle Swarm Optimization*) foi inicialmente desenvolvida por Kennedy e Eberhard (1995) para resolver funções contínuas não lineares. O PSO se baseia tanto na vida artificial, em particular no comportamento de indivíduos sociais como bando de pássaros, cardume de peixes e enxames, quanto em programação evolucionária. Além disso, é um sistema que contém memória e com isso guarda todo o conhecimento de boas soluções não somente sociais como também individuais (EBERHART; KENNEDY, 1995; KENNEDY; EBERHART, 1995).

Javaid et al. (2016) utilizam as técnicas Otimização por Enxame de Partículas Binário (BPSO), Algoritmo Genético (GA do inglês *Genetic Algorithm*) e Busca Cuco (CS do inglês *Cuckoo Search*) para realizar a otimização de um HEMS (do inglês Home Energy Management System) minimizando o custo com energia e os picos de potência. Os autores simulam casas tradicionais sem nenhum sistema e casas inteligentes com ou sem energia renovável e baterias, contendo seis dispositivos onde somente quatro podem ser interrompidos após o acionamento. Todos os algoritmos testados apresentaram uma redução considerável do custo com a energia e dos picos de potência, sendo o CS com a maior redução. Porém, o GA beneficia os usuários com uma redução do custo em conjunto com um conforto relativamente aceitável e uma ótima utilização da energia renovável.

Em Ahmed et al. (2018) o objetivo é minimizar a conta de eletricidade, reduzir a relação de pico para a média e maximizar o conforto que é considerado como o tempo de espera para acionar a carga. Nesse caso, é utilizado somente uma casa inteligente com três dispositivos e são comparados os métodos BPSO e o *Firefly Algorithm* (FA). O FA apresenta o melhor resultado em relação a minimização do custo e da relação de pico para a média, além de maximizar o conforto do usuário.

Em muitos casos são desenvolvidos algoritmos híbridos de forma a diminuir a complexidade e melhorar o desempenho da técnica. Shafiq et al. (2018), Naz et al. (2018) e Saboor et al. (2018) tem os mesmos objetivos dos demais autores e são realizadas comparações entre diferentes técnicas e os híbridos proposto. Nos três trabalhos os híbridos superam as demais técnicas em relação ao custo, porém não apresentam o melhor equilíbrio entre os consumo e conforto.

Cabrita et al. (2019) não propõe uma comparação entre diferentes técnicas, mas utiliza o GA para analisar a importância do processo de sintonização paramétrica das heurísticas. Os autores concluem que esse fator é decisivo na performance final do algoritmo.

A maioria dos trabalhos dessa área de conhecimento tem como objetivo a minimização do custo de energia, porém quando avaliam o conforto do usuário percebem que há uma compensação entre conforto e consumo, sendo necessário buscar um equilíbrio entre os dois objetivos. Com isso, foi visto a necessidade de propor um algoritmo que busca a minimização do consumo de energia a partir do nível de conforto definido pelo próprio usuário. Além disso, como os trabalhos abordam em geral simulações de residências inteligentes, foi observado também a necessidade de aplicação desse trabalho em um campus inteligente a partir da modelagem de uma amostra de um sistema real.

Esse trabalho tem como objetivo propor a aplicação do algoritmo de Otimização por Enxame de Partículas Binário para resolução de um problema de gerenciamento de energia de um sistema real e complexo. Dessa forma, objetiva também realizar a modelagem matemática de um campus inteligente com tarifa de energia variável no tempo e geração distribuída, incluindo suas restrições e o conforto do usuário. Para isso, foi utilizado como estudo de caso um campus do Instituto Federal Fluminense (IFF), o Polo de Inovação de Campos dos Goytacazes (PICG), que é um campus inteligente com pré-disposição para receber um sistema de gerenciamento de energia.

3.4 Metodologia

Este trabalho classifica-se como pesquisa aplicada quanto a sua natureza, pois tem como objetivo a aplicação prática para solucionar um problema específico. Quanto a sua abordagem classifica-se como uma pesquisa quantitativa devido a coleta, tratamento e aplicação dos dados submetidos ao algoritmo de otimização traduzindo em números as informações (SILVA; MENEZES, 2005).

Do ponto de vista dos seus objetivos é classificada como uma pesquisa exploratória e dos procedimentos técnicos como estudo de caso, pois envolve um estudo profundo de uma aplicação em um problema de maneira a permitir um amplo e detalhado conhecimento (GIL, 1991).

3.4.1 Coleta de dados

Para este trabalho será otimizado um dos prédios do Polo de Inovação de Campos dos Goytacazes, o Bloco B, a partir do levantamento dos dispositivos realizado em junho de 2021. A coleta dos dados dos dispositivos foi realizada através de uma vistoria em todo o PICG junto com um técnico eletricista que trabalha no local. Nesse prédio ocorrem aulas, reuniões,

apresentações e também é o local de trabalho da administração. O levantamento dos dispositivos que serão controlados nesse prédio pode ser encontrado na Tabela 1.

Tabela 1 - Amostra de dispositivos do Bloco B do PICG e suas características

Local	Dispositivo	Qnt.	Pot	Ciclos	H	Hmin	Hmax	Tipo	γ
Sala1	Lâmpadas	6	0,045	1	8	8	22	1	2
Sala2	Lâmpadas	6	0,045	1	7	8	17	1	2
Sala3	Lâmpadas	6	0,045	2	3	8	22	1	2
Sala4	Lâmpadas	6	0,045	1	10	8	22	1	2
Sala de reunião	Lâmpadas	4	0,045	1	4	8	22	2	2
Administração	Lâmpadas	8	0,045	1	7	8	17	1	2
Auditório	Lâmpadas	8	0,045	1	4	8	22	2	2
Corredor	Lâmpadas	9	0,045	1	6	17	23	2	1
Banheiros	Lâmpadas	4	0,045	1	5	17	23	1	1
Sala1	Ar condicionado	1	1,63	1	8	8	22	1	2
Sala2	Ar condicionado	1	2,17	1	7	8	22	1	2
Sala3	Ar condicionado	1	2,17	2	3	8	22	1	2
Sala4	Ar condicionado	1	2,17	1	10	8	22	1	2
Sala de reunião	Ar condicionado	1	1,63	1	4	8	17	2	2
Administração	Ar condicionado	1	1,63	1	7	8	17	1	2
Auditório	Ar condicionado	1	2,17	1	4	8	22	2	2

Fonte: Autora (2022)

A Tabela 1 apresenta a quantidade de dispositivos por local e a potência em quilowatts (kW) de cada um. Além disso, apresenta também suas restrições: duração mínima de horas (H) que o dispositivo tem que estar ligado no dia; quantidade de ciclos, que representa quantas vezes esse tempo de duração deve ser repetido; e, na coluna Tipo, informa se a carga é interrompível (tipo 1) ou não interrompível (tipo 2), isto é, uma vez acionada, não pode ser interrompida antes de completar o tempo de duração. E ainda, apresenta os dados de preferência do usuário que serão utilizados para avaliar o conforto: horário mínimo (Hmin) e máximo (Hmax), que representam a melhor hora para iniciar e desligar o dispositivo, respectivamente; e a coluna γ , que indica se o dispositivo deve ser desligado para o horário de almoço, sendo que 1 indica que não precisa ser desligado e 2 indica que precisa ser desligado.

3.4.1.1 Tarifa de energia

A Tarifa Horária Branca foi aprovada a partir da Resolução Normativa nº 733/2016 da ANEEL (ANEEL, 2016) e a partir de janeiro de 2020 pode ser aplicada a consumidores de baixa tensão, exceto da subclasse baixa renda residencial.

O Polo de Inovação é classificado pela Enel-RJ como consumidor de baixa tensão B3 para Poder Público e segue a tarifa convencional que tem um custo fixo de energia. Porém, caso queira, pode optar pela Tarifa Branca que tem um custo de energia variável no tempo, onde os horários de pico e intermediário são mais caros e o horário fora de pico é mais barato que a tarifa convencional.

Na tarifa convencional o custo da energia em cada hora é de 0,714 reais por quilowatt-hora. Na tarifa branca o custo do horário fora de pico é de 0,571 reais por quilowatt-hora, do horário intermediário é de 0,880 reais por quilowatt-hora e do horário de ponta é de 1,333 reais por quilowatt-hora (ANEEL, 2020). A Figura 2 apresenta um gráfico comparativo dos custos das tarifas.

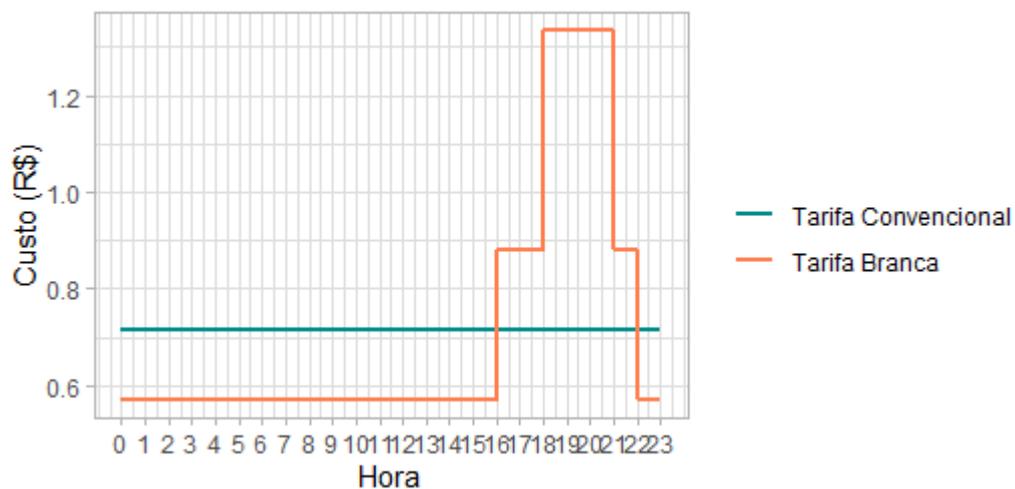


Figura 2 - Comparação entre as tarifas de energia

Fonte: Autora (2022)

3.4.1.2 Geração distribuída e medidores inteligentes

O PICG conta com um sistema de monitoramento de consumo de energia com medidores inteligentes instalados nos prédios e um sistema de painéis solares para geração de energia renovável. Esses sistemas geram dados de consumo e geração de energia por minuto que foram tratados no software R e utilizados para análise do comportamento de consumo e produção de energia do local. Foram utilizados dados de consumo do período de 04 de novembro de 2020 a 01 de dezembro de 2020 e de geração de energia de 25 de setembro de 2020 a 01 de dezembro de 2020.

3.4.2 Modelagem do sistema

Um problema de otimização com restrições pode ser definido como:

Encontre x que minimize $f(x)$ sujeito a

$$g_i(x) \leq 0, i = 1, \dots, m \quad [1]$$

$$h_j(x) = 0, j = 1, \dots, p \quad [2]$$

onde x é um vetor solução, m é o número de restrições de desigualdade e p é o número de restrições de igualdade (MEZURA-MONTES; COELLO, 2008).

Uma das formas de lidar com as restrições é utilizando o método de penalização que foi inicialmente proposto por Courante (1943) e expandido por Carroll (1961) e Fiacco e McCormick (1966). Esse método transforma um problema de otimização com restrições em um problema sem restrições adicionando, em minimizações, ou subtraindo, em maximizações, um certo valor a função objetivo de acordo com a quantidade de restrições que aquela solução viola.

Para esse trabalho foi utilizada a função de penalidade externa estática, proposto por Homaifar et al. (1994), que inicia em uma região infactível e se move para uma região factível e suas penalidades permanecem constantes durante todo o processo para cada nível de violação de forma que o coeficiente de penalização aumenta conforme aumenta o nível de violação. O valor de fitness desse método é dado por:

$$Fitness(x) = f(x) + \sum R_{k,i} * \max [0, g_i(x)]^2 \quad [3]$$

onde $R_{k,i}$ são os coeficientes de penalidade para cada restrição de desigualdade i , $f(x)$ é a função objetivo não penalizada, $k=1, 2, \dots, l$, onde l é o número de níveis de violação definidos pelo usuário. Nesse caso, as restrições de igualdade são transformadas em desigualdades.

Neste trabalho os coeficientes de penalidade da restrição foram definidos baseados no quão distante a solução está da região factível, sendo que quanto mais longe da região factível maior será a penalidade. Considerando u o limite da região factível, temos:

$$R_{k,i} = \frac{u - g_i(x)}{u} \quad [4]$$

3.4.2.1 Função consumo

O objetivo relacionado ao consumo busca encontrar o melhor agendamento dos dispositivos para cada hora do dia, levando em conta o preço da tarifa de energia e a quantidade de energia produzida pela geração distribuída, de forma a minimizar o custo da eletricidade consumida. Portanto, a função consumo (F_{cons}) é expressa da seguinte forma:

$$F_{cons} = \sum_{i \in D} \sum_{t \in T} EC_i(t) * TAR(t) - \sum_{t \in T} EGD(t) * TAR(t) \quad [5]$$

onde $EC_i(t)$ é a energia consumida pelo dispositivo i na hora t , $D = \{1, 2, \dots, i, \dots, ndisp\}$ é o conjunto de $ndisp$ dispositivos disponíveis, $T = \{0, 1, \dots, t, \dots, 23\}$ é o conjunto dos possíveis horários de acionamento das cargas, $TAR(t)$ é custo da tarifa de energia na hora t e $EGD(t)$ é a energia gerada na hora t . A energia consumida pelos dispositivos é representada por:

$$EC_i(t) = n_i * Pot_i * \sigma_{it} \quad [6]$$

onde n_i é a quantidade desse dispositivo, Pot_i é a potência gasta pelo dispositivo em quilowatt e σ_{it} é um operador binário que indica se o dispositivo está ligado ou desligado (1 ou 0) na hora t .

3.4.2.2 Função conforto

Outro objetivo deste trabalho é a otimização do conforto, que se refere ao quão distante está o acionamento das cargas em relação a preferência do usuário. O usuário define o horário mínimo (H_{min}) para iniciar as cargas e o horário máximo (H_{max}) para último acionamento de cada dispositivo. A função de conforto (F_{conf}) é expressa da seguinte forma:

$$F_{conf} = \sum_{i \in D} \left(\sum_{t=0}^{H_{min}} \sigma_{it} \frac{H_{min} - t}{H_{min} - 0} + \sum_{t=H_{max}}^{23} \sigma_{it} \frac{t - H_{max}}{23 - H_{max}} \right) \quad [7]$$

onde os numeradores das frações representam a diferença entre o instante escolhido pelo usuário e o instante agendado pelo algoritmo e os denominadores representam a maior distância entre o horário definido pelo usuário e o limite de acionamento. Com isso, quanto mais distante o agendamento estiver da preferência do usuário maior será o desconforto e o resultado da função e quanto mais próximo menor o resultado e o desconforto.

3.4.2.3 Função restrição

Nesse trabalho considera-se que as cargas podem assumir dois estados, ligado ou desligado e podem ser de dois tipos, cargas interrompíveis ou não interrompíveis. Além disso, as cargas não interrompíveis podem ter uma quantidade de ciclos de acionamento maior do que um. Assim, para a formulação do modelo matemático proposto para o problema, mais notações se fazem necessárias:

Conjuntos:

- $D = \{1, 2, \dots, i, \dots, ndisp\}$: conjunto dos dispositivos disponíveis;

- NI : conjunto de todas as cargas não interrompíveis;
- $T = \{0, 1, \dots, t, \dots, 23\}$: conjunto dos possíveis horários de acionamento das cargas
- $I = \{0, 1, \dots, j, \dots, 24 - H_i\}$ conjunto dos tempos disponíveis para os acionamentos das cargas não interrompíveis;

Dados:

- H_i : tempo de duração em horas da carga i ;
- $ciclos_i$: número de vezes que a carga $i \in NI$ deverá ser acionada e permanecer ligada por H_i horas;

Variáveis:

- $\delta_{ij} = \begin{cases} 1, & \text{se a carga } i \text{ for acionada no instante } j; \\ 0, & \text{caso contrário;} \end{cases}$
- $\sigma_{it} = \begin{cases} 1, & \text{se a carga } i \text{ estiver ligada no instante } t; \\ 0, & \text{caso contrário;} \end{cases}$

As restrições relacionadas as cargas podem ser expressas pelas Restrições [8] a [13].

$$\sum_{t \in T} \sigma_{it} \geq H_i ciclos_i \quad \forall i \in D \quad [8]$$

$$\sum_{t=j}^{j+H_i-1} \sigma_{it} = H_i \delta_{ij} \quad \forall i \in NI, \forall j \in I \quad [9]$$

$$\sum_{j \in I} \delta_{ij} = ciclos_i \quad \forall i \in NI \quad [10]$$

$$\sum_{k=j}^{j+H_i-1} \delta_{ik} \leq 1 \quad \forall i \in NI, \forall j \in I \quad [11]$$

$$\sigma_{i,12} + \sigma_{i,13} = 0 \quad \forall i \in D, \forall \gamma = 2 \quad [12]$$

$$\sigma_{it} \in \{0, 1\}, \delta_{ij} \in \{0, 1\} \quad \forall i \in D, \forall t \in T, \forall j \in I \quad [13]$$

As Restrições [8] representam a duração mínima geral dos dispositivos, onde o somatório de horas do dispositivo i ligado dentro do intervalo de 24 horas deve ser maior ou igual ao tempo de duração H_i vezes a quantidade de ciclos que essa duração deve se repetir. No caso das cargas interrompíveis esses acionamentos podem ser distribuídos ao longo do dia.

As Restrições [9] garantem que as cargas não interrompíveis i , uma vez acionadas no instante t , permaneçam ligadas durante H_i horas.

As Restrições [10] representam o comportamento das cargas não interrompíveis que devem ser acionadas uma quantidade de $ciclos_i$ vezes dentro do intervalo de tempo I , ou seja,

uma vez acionada não pode alterar de estado até que tenha completado seu tempo de duração H_i .

As Restrições [11] garantem que não haja sobreposição de ciclos para as cargas não interrompíveis i com $ciclos_i > 1$. Ou seja, uma vez acionada em determinada hora, a mesma deverá permanecer ligada por H_i horas só podendo ser acionada novamente após esse período.

As Restrições [12] representam o acionamento da carga durante o horário de almoço, onde γ representa se o dispositivo deve ser ligado ou desligado de 12h às 13h, sendo que se γ for igual a 2 a carga desse ser desligada. Por último, as Restrições [13] definem as variáveis de decisão do modelo como sendo binárias do tipo 0 – 1.

O algoritmo lida com as restrições através do método de penalização externa estática descrita do tópico 3.4.2 deste trabalho, onde cada nível de violação tem um coeficiente de penalização que é maior quanto mais distante a solução estiver da região factível. Com isso, um problema com restrições é representado como um problema sem restrições fazendo com que o algoritmo aceite soluções fora da região factível e a penalização o faz encontrar a região factível.

Na restrição de duração mínima geral dos dispositivos a penalidade aumenta quanto mais distante estiver do tempo de duração mínimo. Na restrição do comportamento de cargas não interrompíveis a penalidade aumenta quanto mais interrupções a carga tiver ao longo do dia. E na restrição do acionamento da carga durante o intervalo de almoço a penalidade aumenta a cada vez que um dispositivo com γ igual a 2 é acionado às 12h ou 13h.

3.4.2.4 Função objetivo

A função custo desse trabalho é dada pelo somatório das funções consumo, conforto e restrição. Além disso, as funções consumo e conforto são associadas a uma variável α que define o nível de conforto desejado pelo usuário, conforme a Equação [14].

$$F_{custo} = \alpha * F_{cons} + (1 - \alpha)F_{conf} * P_{conf} + F_{rest} * P_{rest} \quad [14]$$

A constante α é um valor de 0 a 1 onde, quanto mais próximo de zero, maior é o nível de conforto no resultado final do algoritmo, e quanto mais próximo de um, menor é o conforto. As variáveis P_{conf} e P_{rest} são pesos de nivelamento para as funções conforto e restrição, respectivamente. Com isso, transforma-se um problema multiobjetivo com restrições em um problema de otimização mono-objetivo sem restrições. Já o problema mono-objetivo com restrições é representado pelo seguinte modelo de Programação Linear Inteira (PLI):

$$\begin{aligned}
\text{Min } F_{custo} &= \alpha * F_{cons} + (1 - \alpha)F_{conf} * P_{conf} \\
\text{s. a.:} \\
\sum_{t \in T} \sigma_{it} &\geq H_i \text{ciclos}_i && \forall i \in D \\
\sum_{t=j}^{j+H_i-1} \sigma_{it} &= H_i \delta_{ij} && \forall i \in NI, \forall j \in I \\
\sum_{j \in I} \delta_{ij} &= \text{ciclos}_i && \forall i \in NI \\
\sum_{k=j}^{j+H_i-1} \delta_{ik} &\leq 1 && \forall i \in NI, \forall j \in I \\
\sigma_{i,12} + \sigma_{i,13} &= 0 && \forall i \in D, \forall \gamma = 2 \\
\sigma_{it} \in \{0, 1\}, \delta_{ij} &\in \{0, 1\} && \forall i \in D, \forall t \in T, \forall j \in I
\end{aligned}$$

3.4.3 Otimização por Enxame de Partículas (PSO)

O PSO inicializa gerando uma população de soluções aleatórias chamadas de partículas e uma velocidade aleatória para cada solução potencial fazendo com que as partículas "voem" pelo espaço de busca (KENNEDY; EBERHART, 1995).

As coordenadas de cada partícula i são armazenadas em um vetor de posição X_i e em um loop de iterações as partículas conduzem repetidos experimentos passando por diversas posições (KENNEDY, 1997).

Cada partícula armazena as coordenadas da melhor posição encontrada por ela até o momento e o custo dessa solução obtido pela função objetivo. A melhor solução da partícula i é chamada de $pbest_i$, enquanto que a melhor solução global e sua localização, que pode ter sido obtido por qualquer uma das partículas na população, é chamada de $gbest$.

A cada passo a velocidade de cada partícula é alterada por um termo aleatório fazendo com que acelerem em direção ao seu $pbest_i$ e $gbest$ (KENNEDY; EBERHART, 1995). As partículas atualizam suas velocidades e posições de acordo com as Equações [15] e [16], respectivamente:

$$V_i(t+1) = V_i(t) + c_1 * r_1 (pbest_i(t) - X_i(t)) + c_2 * r_2 (gbest(t) - X_i(t)) \quad [15]$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad [16]$$

onde, t representa a iteração, c_1 e c_2 são constantes positivas chamadas de coeficientes de aceleração e r_1 e r_2 são valores aleatórios uniformemente distribuídos entre 0 e 1. O vetor

velocidade V_i é limitado por um valor V_{max} de forma que se $V_i > V_{max}$, então $V_i = V_{max}$, ou caso $V_i < -V_{max}$, então $V_i = -V_{max}$.

Em Kennedy (1997), o autor divide a fórmula de velocidade V_i em dois termos, o termo "cognitivo" e o termo "social". O vetor de diferenças ($pbest_i - X_i$) representa a distância entre a posição da melhor solução encontrada pela partícula e a sua posição atual, sendo assim o termo "cognitivo". O vetor de diferenças ($gbest - X_i$) representa a distância entre a posição da melhor solução global encontrada e a posição atual da partícula, sendo considerado o termo "social".

A partir das Equações [15] e [16] podemos representar através de vetores o comportamento exploratório da partícula para encontrar a melhor solução, conforme Figura 3.

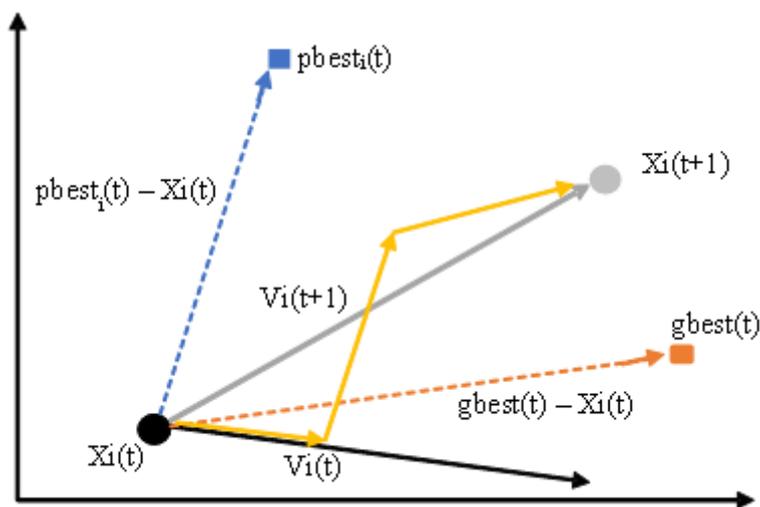


Figura 3 - Representação vetorial do comportamento das partículas

Fonte: Autora (2022)

3.4.3.1 PSO Binário

Para problemas relacionados a escalonamento os métodos de otimização devem encontrar a melhor distribuição dos recursos dentro do horizonte de planejamento. Considerando o agendamento de dispositivos elétricos abordado nesse trabalho, deve-se encontrar os melhores horários para ligar ou desligar um aparelho em função do custo e da geração de energia levando em conta a satisfação do usuário e as restrições do problema.

Como o custo tarifário sofre alterações de acordo com a hora do dia, sem alterações durante os minutos, optou-se pela representação binária desse problema. Além disso, o sistema se propõe a otimizar somente cargas que demandam um maior tempo de duração (blocos de horas) quando acionadas e que são mais flexíveis quanto ao horário de funcionamento, como lâmpadas e ar condicionados. De acordo com o levantamento de dados realizado no PICG, esses

dispositivos aparecem em grande quantidade no campus sendo 116 lâmpadas e 19 ar condicionados de diferentes potências instalados até junho de 2021, representando uma grande parte da energia consumida que pode ser responsável por um maior custo de eletricidade se não for bem gerenciada. Com isso, o cenário foi modelado com variáveis de decisão binárias, onde 0 é considerado que o dispositivo está desligado e 1 o dispositivo está ligado.

O PSO foi inicialmente proposto para resolver problemas de otimização em um espaço de variáveis reais, porém em Kennedy e Eberhart (1997) os autores apresentam uma versão binária do algoritmo, o *Binary Particle Swarm Optimization* (BPSO).

No espaço binário as partículas se movimentam no espaço de busca variando os números de bits e sua velocidade pode ser descrita como o número de bits que foram alterados na iteração. Com isso, uma partícula se move em um espaço de estado restrito a zero ou um em cada dimensão e a atualização da velocidade da partícula V_i é a probabilidade do bit x_i mudar de estado (KENNEDY; EBERHART, 1997).

O BPSO mantém a maior parte das ideias gerais da versão canônica e a equação de atualização da velocidade da partícula V_i permanece inalterada, porém, agora as posições dos vetores $pbest_i$ e X_i só podem assumir os valores inteiros 0 ou 1 e v_i será uma probabilidade dentro do intervalo [0.0, 1.0]. A atualização da posição será definida por:

$$x_i = \begin{cases} 1, & \text{se } rand() < S(v_i) \\ 0, & \text{c. c.} \end{cases} \quad [17]$$

$$S(v_i) = \frac{1}{1 + e^{-v_i}} \quad [18]$$

onde, $S(v_i)$ é uma função Sigmóid e $rand()$ é um valor aleatório selecionado de uma distribuição uniforme em [0.0, 1.0] (KENNEDY; EBERHART, 1997).

Assim como na forma canônica, também podemos limitar a velocidade definindo uma constante V_{max} . Nesse caso, a limitação faz com que $S(v_i)$ não se aproxime nem de zero nem de um, garantindo que tenha uma chance de o bit mudar de estado. Em geral, o valor de V_{max} é frequentemente definido como ± 4.0 e o somatório das constantes c_1 e c_2 igual a 4.0 (KENNEDY; EBERHART; SHI, 2001).

3.4.4 Agendamento dos dispositivos

O indivíduo do enxame é representado nesse trabalho pela seguinte estrutura:

$$X = \left[X_{ndisp_{(1 \times h)}} \right]_{(1 \times ndisp)} \quad [19]$$

onde, h é a quantidade de horas no dia, $ndisp$ é a quantidade de dispositivos que serão agendados e as dimensões binárias (X_{ndisp}) representam o estado dos dispositivos a cada hora do dia, sendo que 0 é desligado e 1 é ligado. Com isso, o vetor solução possui como dimensão (dim) a quantidade de horas do dia multiplicado pelo número de dispositivos, ou seja, $dim=24*16=384$. Para cada novo dispositivo acrescentado no planejamento serão acrescentadas no vetor mais 24 posições.

Sendo assim, este é um problema de larga escala, justificando a necessidade de aplicação de uma meta-heurística para encontrar o melhor resultado para esse problema. Diante disso, no Pseudocódigo 1 é apresentado um resumo do algoritmo BPSO que foi implementada neste trabalho.

Pseudocódigo 1: Otimização por Enxame de Partículas Binário (BPSO)

Entrada: dados dos dispositivos, dados de geração de energia, tarifa de energia, função consumo, função conforto, função restrição, dimensão (dim), nº máximo de iterações ($MaxIt$), tamanho da população ($popsiz$), nível de conforto ($alpha$).

1. Inicializa melhor resultado global $gbest$ com valor infinito;
2. Gerar aleatoriamente a velocidade e a posição da população inicial;
3. Calcula o custo da função objetivo para cada partícula com a Equação [14];
4. Armazena o melhor resultado pessoal $pbest_i$ de cada partícula com a posição inicial;
5. Atualiza o $gbest$ com o menor valor $pbest_i$ entre as partículas;
6. **para** $it=1$ **até** $MaxIt$ **faça:**
7. **para** $i=1$ **até** $popsiz$ **faça:**
8. Atualiza a velocidade V_i com a Equação [15];
9. **para** $j=1$ **até** (tamanho de V_i) **faça:**
10. Aplica limites de velocidade V_{min} e V_{max} ;
11. Atualiza a posição X_i com as Equações [17] e [18];
12. **fim-para**
13. Calcula o custo da função objetivo para cada partícula;
14. Atualiza o menor $pbest_i$;
15. Atualiza o menor $gbest$;
16. **fim-para**
17. **fim-para**

Saída: agendamento horário dos dispositivos

3.4.5 Parametrização do BPSO

O BPSO tem um funcionamento simples e poucos parâmetros, o que faz dele um dos algoritmos mais buscados e de fácil manuseio. O limite de velocidade e os coeficientes de velocidade recebem valores testados e indicados pelos autores e criadores do algoritmo, Kennedy e Eberhart (1997), então o único parâmetro a ser variado para testar sua eficiência é o tamanho da população. Foram realizados testes para diferentes tamanhos de população com o nível de conforto fixo em 0.5 de forma a equilibrar conforto e consumo.

O código foi criado em linguagem *Python* através da IDE (*Integrated Development Environment*) *Spyder 4.2.0 (The Scientific Python Development Environment)* e executado em um computador com as seguintes características:

- Sistema Operacional: *Windows 10 Home Single Language* 64bits;
- Processador: Intel(R) Core(TM) i5-5200U CPU @ 2.20GHz 2.20 GHz;
- Memória RAM: 8,00GB;
- Disco Rígido: 1TB de HD;
- Placa de vídeo: NVIDIA GeForce 920M.

A metaheurística foi executada 20 vezes para cada tamanho de população, obtendo a média e o desvio padrão do custo final da função objetivo e dos valores de desconforto e restrição para cada resultado. Além disso, foi verificado também a média e desvio padrão do tempo de execução de um ciclo em segundos.

Após a parametrização do algoritmo, com o tamanho de população definido a partir do teste anterior, foi realizada a avaliação do algoritmo BPSO no problema de gerenciamento de energia inteligente por meio de testes para diferentes níveis de conforto do usuário. Uma simulação do menor custo possível com a Tarifa Convencional foi utilizado como base para análise com os resultados utilizando Tarifa Branca.

Para todos os testes foram utilizados os seguintes parâmetros para o algoritmo BPSO:

- Parâmetro cognitivo e social: $c_1=2$ e $c_2=2$ (recomendados pela literatura);
- Número máximo de iterações: 1000 (com condição de parada caso não haja melhora em 100 iterações);
- Velocidade máxima e mínima: $V_{max}=4$ e $V_{min}= -V_{max}$

Em todos os testes com o BPSO foi utilizado o problema de otimização mono-objetivo sem restrições descrita na Equação [14]. Para nivelar as funções conforto e restrição em relação à função consumo foram definidos os pesos P_{conf} igual à 20 e P_{rest} igual à 100 para todos os testes.

O primeiro teste foi realizado para as populações de tamanho 5, 10, 30, 50 e 80 e o segundo teste para os níveis de conforto 0.0, 0.2, 0.5, 0.8 e 1.0, sendo que 0.0 é o máximo de conforto e 1.0 desconsidera o conforto.

3.4.6 Avaliação do BPSO frente ao CPLEX

O software comercial IBM ILOG CPLEX *Optimization Studio* é um conjunto de ferramentas que permite resolver problemas complexos de otimização utilizando um método exato. Devido a sua grande capacidade de obter o ótimo, o CPLEX fornece uma boa métrica para comparação com outros métodos. Porém, em instâncias muito grandes pode apresentar um tempo alto de execução.

Neste trabalho foi realizada a comparação do BPSO em relação ao IBM ILOG CPLEX *Optimization Studio Community Edition 20.1* em quatro instâncias com diferentes quantidades de dispositivos conforme Tabela 2, considerando a Tarifa Horária Branca. Para esses testes foram utilizados os mesmos valores dos parâmetros e o mesmo computador do tópico anterior, alterando somente os pesos P_{conf} e P_{rest} para 1000 e 20, respectivamente.

O BPSO foi executado 10 vezes para cada instâncias, considerando o nível de conforto igual a 0,5 e com interrupção das iterações somente ao encontrar o ótimo. O CPLEX foi implementado com o *Pyomo* que é uma linguagem de modelagem de otimização de código-fonte aberto baseada na linguagem *Python* na IDE *Spyder*. Dentre os diversos *solvers* disponibilizados pela linguagem, foi selecionado o CPLEX IBM *Solver*. Em todos os testes com o CPLEX foi utilizado o problema de otimização mono-objetivo com restrições descrito no tópico 3.4.2.4 deste trabalho com P_{conf} igual a 1000.

Tabela 2 – Instâncias para comparação

Instância	1	2	3	4
Nº de dispositivos	4	6	8	16

Fonte: Autora (2022).

3.5 Resultados e discussão

A partir da coleta e tratamento dos dados do PICG foram obtidos os gráficos de consumo médio horário do Bloco B e de geração média horária do grupo de painéis, Solar 5. A Figura 4 apresenta o gráfico com o consumo médio horário no Bloco B.

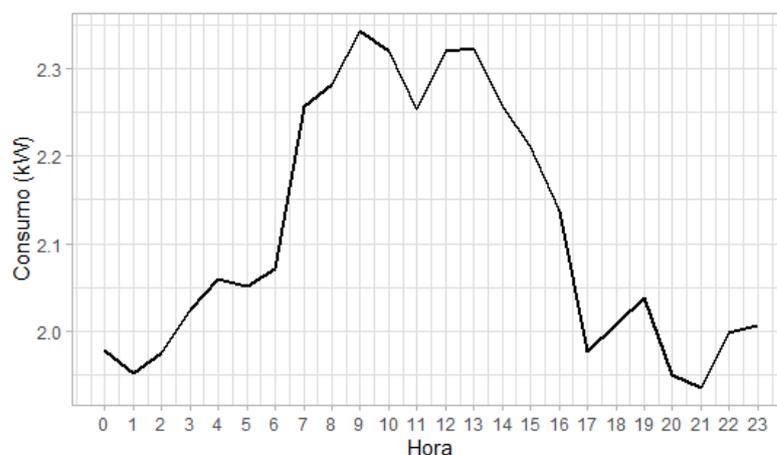


Figura 4 - Consumo de energia do Bloco B do PICG

Fonte: Autora (2022)

O consumo tem um aumento a partir das 06 horas e reduz às 17 horas com uma pequena queda no horário de almoço por volta das 11-12 horas, condizendo com o horário de expediente dos funcionários do PICG. Também há um consumo regular no período da noite por causa da iluminação dos corredores e de dispositivos fixos que não podem ser desligados. Devido a pandemia de COVID-19, no período analisado somente poucos funcionários tinham acesso ao local e as aulas não estavam ocorrendo presencialmente. Com isso, para este trabalho foram considerados também os horários que normalmente ocorriam as aulas, apresentações e reuniões no Polo que eram mais concentradas no período da tarde e da noite.

Na Figura 5 apresenta o gráfico com a média horária da geração de energia no Polo.

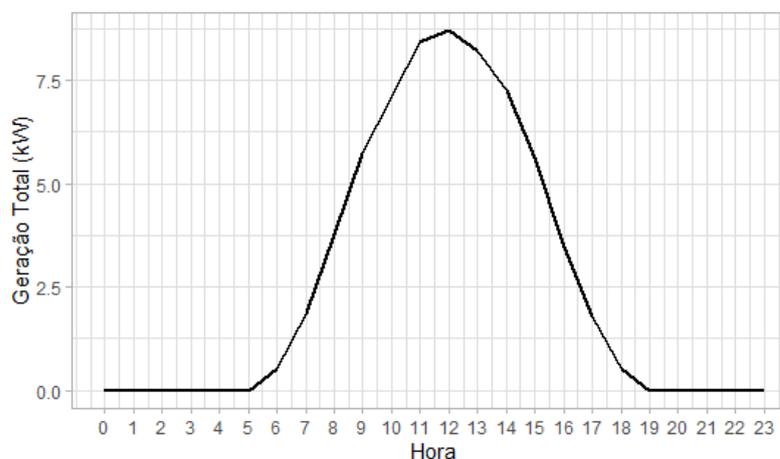


Figura 5 - Geração de energia do PICCG

Fonte: Autora (2022)

A geração de energia inicia às 06 horas e reduz às 18 horas, não havendo geração durante a noite e tendo um pico entre às 10 horas e 15 horas.

3.5.1 Comparação entre tamanhos de população

A Tabela 3 apresenta a média e o desvio padrão do custo final obtido pela Função Objetivo, do desconforto gerado pelos resultados e da restrição, onde uma restrição igual a zero indica que o resultado está na região factível. Além disso, apresenta as mesmas medidas também para o tempo de execução para cada teste em segundos.

Tabela 3 - Média e desvio padrão do teste de parametrização

	População	5	10	30	50	80
Média	Custo	156,70	116,34	82,22	72,65	71,10
	Consumo	85,65	83,60	84,18	83,52	78,29
	Desconforto	9,60	6,58	3,97	2,96	2,65
	Restrição	0,18	0,09	0,004	0,01	0,05
	Tempo	68,57	111,52	319,01	517,60	811,01
Desvio Padrão	Custo	34,06	23,70	12,41	9,73	18,56
	Consumo	4,78	5,73	6,37	6,39	5,78
	Desconforto	2,48	2,11	1,16	0,98	1,12
	Restrição	0,16	0,09	0,02	0,04	0,08
	Tempo	21,18	18,63	58,47	119,23	209,40

Fonte: Autora (2022)

Analisando o resultado dos testes de parametrização foi possível notar o quanto o tamanho da população influencia diretamente no tempo de execução, que é maior quanto maior é a população. Porém, esse parâmetro também tem influência no desempenho do algoritmo em relação a encontrar a melhor solução, pois em populações muito pequenas as partículas não conseguem abranger uma parte maior do espaço de busca. Com isso, demoram mais a convergir e ter estabilidade sendo necessário um maior número de iterações, conforme pode ser visto na Figura 6 que apresenta o comportamento do BPSO ao longo das 1000 iterações para um teste com 5 partículas.

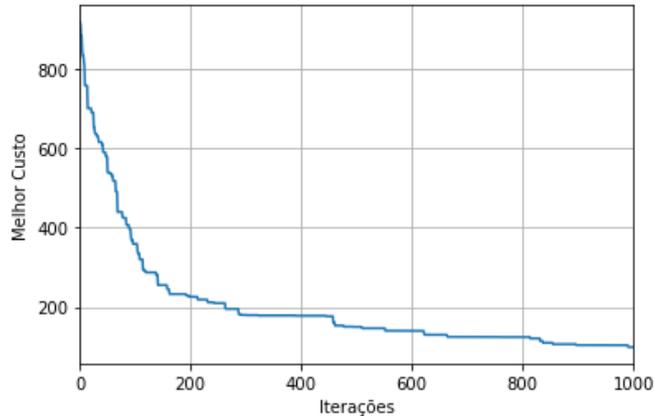


Figura 6 - Convergência do BPSO com 5 partículas

Fonte: Autora (2022)

Com um maior número de partículas, o espaço de busca é mais explorado e aumenta as chances de o algoritmo encontrar a solução ótima e também consegue ter uma maior estabilidade, conforme pode ser visto na Figura 7 que apresenta o comportamento do BPSO ao longo das 1000 iterações para um teste com 80 partículas.

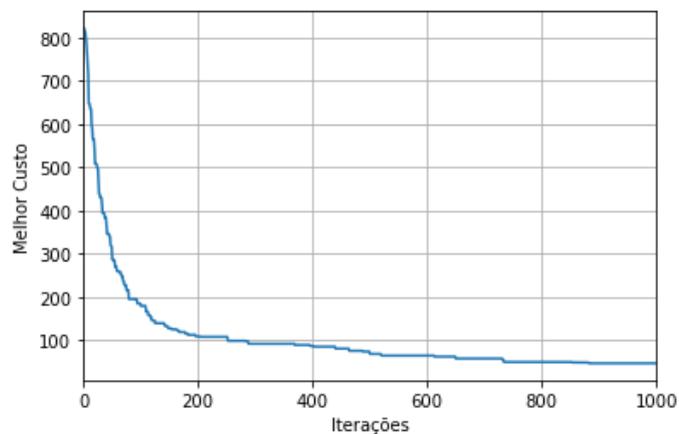


Figura 7 - Convergência do BPSO para 80 partículas

Fonte: Autora (2022)

Acima de 30 partículas na população, o algoritmo encontra custos menores e com menos variação e também tem menos resultados fora da região factível, indicando que entre 30 e 80 partículas o algoritmo está mais próximo da solução ótima, porém o tempo também aumenta consideravelmente.

A população com 50 partículas foi considerada o melhor resultado, pois tem um custo bem próximo da melhor solução obtida com 80 partículas, porém tem um tempo de execução

menor e mais próximo do obtido com 30 partículas. Sendo assim, tem tanto as vantagens da população igual à 30 quanto da população igual à 80.

3.5.2 Comparação entre os níveis de conforto

A Figura 8 apresenta um gráfico *boxplot* dos valores de custo obtidos para cada nível de conforto nos 20 testes realizados.

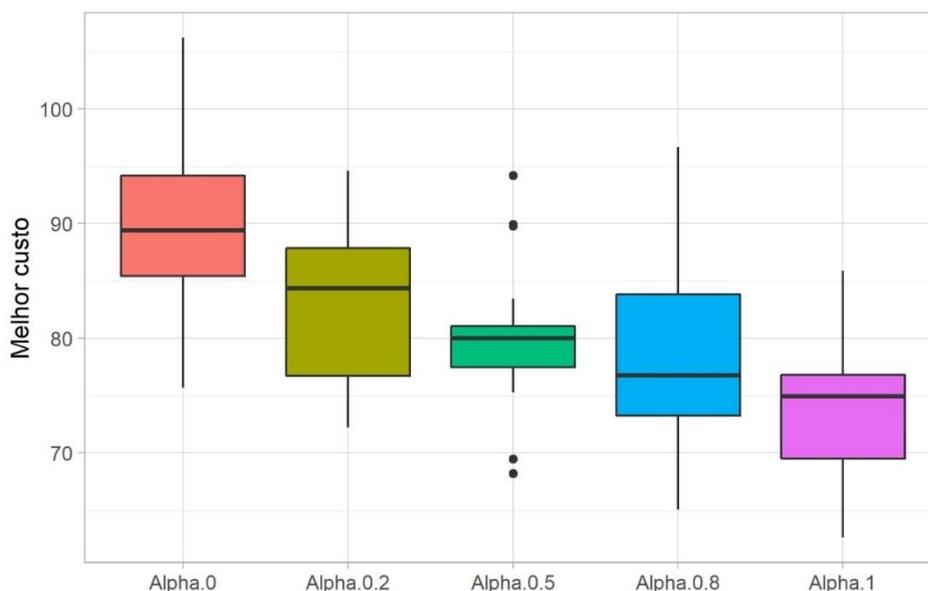


Figura 8 - *Boxplot* dos melhores custos para cada nível de conforto

Fonte: Autora (2022)

Na Tabela 4 estão os resultados para consumo, desconforto do usuário e restrição para o melhor custo da função objetivo e as médias e desvio padrão de cada objetivo para os 20 testes realizados em cada nível.

Tabela 4 - Melhor resultado para cada nível de conforto

		Melhor	Média	Desvio Padrão
0.0	Consumo	93,36	89,92	7,05
	Desconforto	0,62	1,92	1,11
	Restrição	0	0,06	0,1
0.2	Consumo	78,20	82,93	6,65
	Desconforto	0,91	1,98	0,66
	Restrição	0	0,04	0,07

0.5	Consumo	78,10	80,06	6,20
	Desconforto	1,80	3,25	1,07
	Restrição	0	0,03	0,09
0.8	Consumo	70,98	77,91	7,84
	Desconforto	8,21	13	3,75
	Restrição	0	0,01	0,04
1.0	Consumo	62,60	74	6,39
	Desconforto	46,84	55,49	4,93
	Restrição	0	0	0

Fonte: Autora (2022)

Em todos os níveis todas as restrições para o melhor custo são iguais a zero, indicando que nenhuma delas foi violada. Pela média da restrição para os 20 testes nota-se que a presença de soluções na região infactível, principalmente quando o nível de conforto se aproxima de zero, onde a média é maior. Isso cria uma possível relação entre o espaço de busca, que é menor quando o conforto é maior, e o peso da restrição, pois em alguns testes o algoritmo encontra um melhor custo para a função objetivo mesmo sofrendo penalidade devido a restrição.

Em relação ao desconforto, o algoritmo consegue manter valores bem baixos até o nível 0.8. Para o nível 1 há um aumento acentuado do desconforto do usuário e quanto maior o nível também é maior o desvio padrão, pois o conforto é pouco ou totalmente desconsiderado e é levado mais em conta o menor consumo que pode estar próximo ou não do conforto. Porém, em outro extremo, quando o conforto é máximo tem-se um consumo consideravelmente mais elevado. Com isso, nota-se a importância de um bom gerenciamento das cargas ao aplicar a Tarifa Branca para que não haja prejuízo ao usuário.

A média de consumo obtida com a Tarifa Convencional é de 90 reais por dia para os dispositivos considerados no Bloco B. Com isso, através da Tabela 4 e da Figura 8 é possível notar que o BPSO consegue realizar uma redução considerável do custo com eletricidade, principalmente quando o nível de conforto é diminuído, indicando a compensação entre custo e conforto encontrados por Javaid *et al.* (2016), Ahmed *et al.* (2018), Shafiq *et al.* (2018), Naz *et al.* (2018) e Saboor *et al.* (2018).

A Figura 9 ilustra graficamente o padrão de consumo de energia horário para cada nível de conforto do sistema otimizado com a Tarifa Branca e com a Tarifa Convencional. A linha preta representa o consumo em quilowatt-hora, a linha vermelha a energia gerada por hora, a

faixa mais sombreada representa o horário de pico e a menos sombreada o horário intermediário.

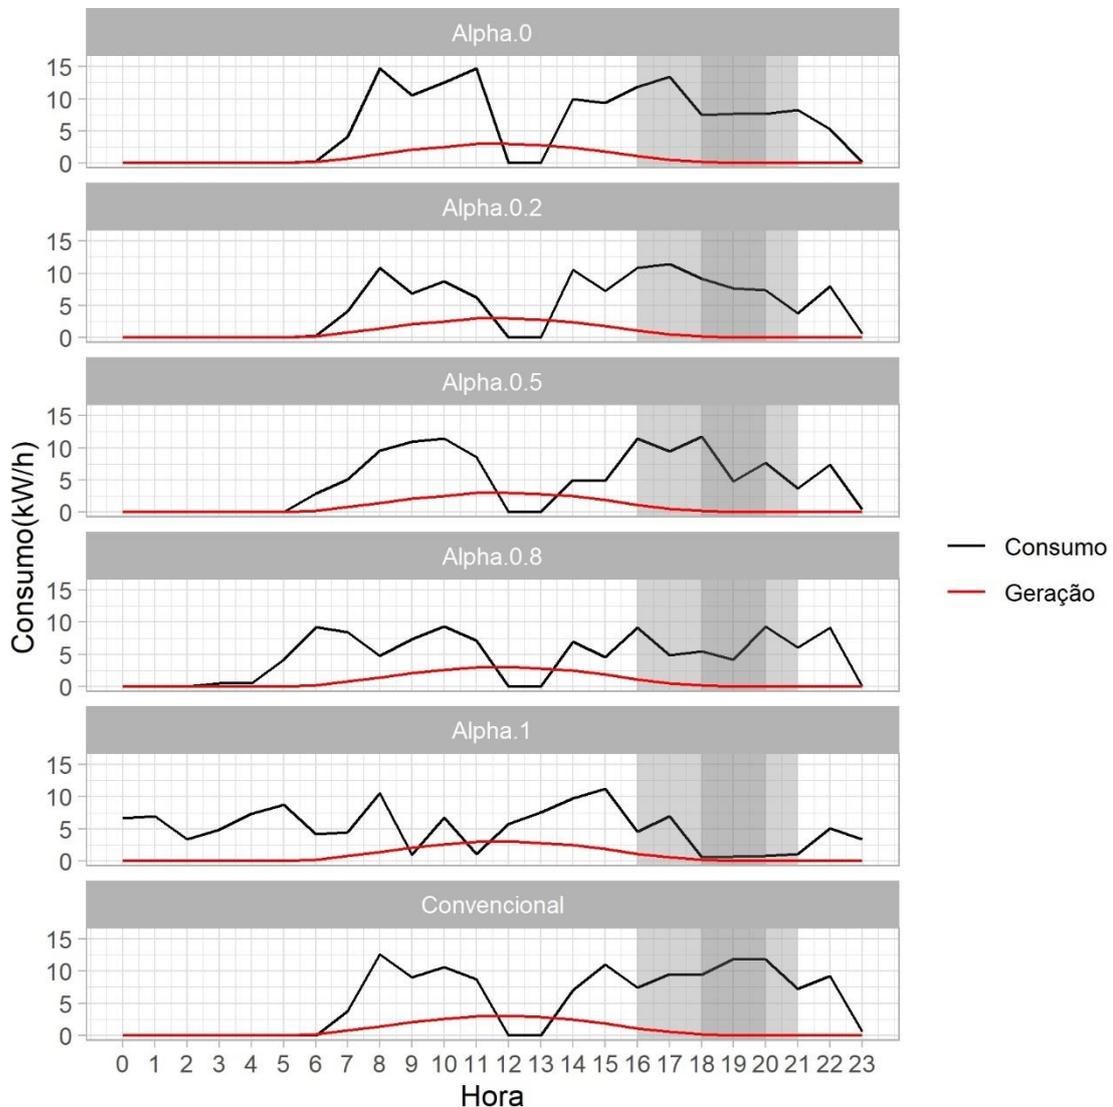


Figura 9 - Gráficos de consumo de energia horário para cada resultado

Fonte: Autora (2022)

O gráfico da Tarifa Convencional representa o padrão de consumo com conforto máximo que levaria ao menor custo que o usuário poderia ter. No caso da Tarifa Convencional o nível de conforto é irrelevante, pois a tarifa não varia com o tempo. Com isso, qualquer deslocamento no agendamento resultaria no mesmo custo total. A partir desse gráfico podemos observar o quanto o padrão de consumo muda a partir do nível de conforto.

Em relação aos gráficos da Tarifa Branca, foi observado que quanto menos o conforto é considerado (nível próximo de 1) mais o algoritmo reduz o consumo no horário de pico e intermediário, porém nesse caso o agendamento dos dispositivos se distancia totalmente do que

condiz com a realidade dos usuários. E quanto mais o conforto é considerado, maior é o consumo nesse horário e é mais condizente com a realidade dos usuários. Com isso, os níveis 0.5 e 0.8 podem ser utilizados para um maior equilíbrio entre consumo e conforto, pois são próximos do padrão do consumidor e apresentam um consumo mais baixo no horário de pico, em relação a níveis mais próximos de zero. As Figuras 10 e 11 apresentam o agendamento dos dispositivos para os níveis 0.5 e 0.8.

Dispositivo - Local	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
Lâmpadas - Sala1	0	0	0	0	0	0	0	0	1	1	1	0	0	0	1	1	1	0	0	0	1	0	1	0
Lâmpadas - Sala2	0	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0	1	0	0	0	0	0	0	0
Lâmpadas - Sala3	0	0	0	0	0	0	1	0	0	1	0	1	0	0	1	0	0	1	0	0	0	1	1	0
Lâmpadas - Sala4	0	0	0	0	0	0	0	1	0	0	1	1	0	0	1	1	1	1	1	0	1	1	1	0
Lâmpadas - Sala de reunião	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0	0	1	1	1	1	0	0
Lâmpadas - Administração	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	0	1	1	0	0	0	0	0	0
Lâmpadas - Auditório	0	0	0	0	0	0	0	0	1	1	1	1	0	0	0	1	1	1	1	1	1	1	1	0
Lâmpadas - Corredor	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1
Lâmpadas - Banheiros	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	0	1	0	1	0
Ar condicionado - Sala1	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	1	1	1	1	1	0	1	0
Ar condicionado - Sala2	0	0	0	0	0	0	0	1	1	0	1	0	0	0	0	1	0	1	1	0	0	0	0	1
Ar condicionado - Sala3	0	0	0	0	0	0	0	0	1	1	1	0	0	0	1	0	1	0	1	0	0	0	0	1
Ar condicionado - Sala4	0	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0	1	0	1	0	1	1	0	0
Ar condicionado - Sala de reunião	0	0	0	0	0	0	0	0	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
Ar condicionado - Administração	0	0	0	0	0	0	0	0	0	1	1	1	0	0	1	1	1	1	0	0	0	0	0	0
Ar condicionado - Auditório	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	0

Figura 10 - Agendamento dos dispositivos para o nível de conforto 0.5

Fonte: Autora (2022)

Dispositivo - Local	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
Lâmpadas - Sala1	0	0	0	0	0	0	0	1	0	0	1	1	0	0	1	1	1	1	0	0	0	1	0	0
Lâmpadas - Sala2	0	0	0	0	0	0	0	1	1	1	1	1	0	0	1	0	0	1	1	0	0	0	0	0
Lâmpadas - Sala3	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	1	1	1	1	0	1	0	0
Lâmpadas - Sala4	0	0	0	0	0	0	1	0	0	1	1	1	0	0	1	0	1	1	0	1	1	1	1	0
Lâmpadas - Sala de reunião	0	0	0	1	1	1	1	0	1	1	1	1	0	0	0	1	1	1	1	1	1	1	1	0
Lâmpadas - Administração	0	0	0	0	0	1	0	1	0	1	1	1	0	0	0	1	0	0	0	1	0	0	0	0
Lâmpadas - Auditório	0	0	0	1	1	1	1	0	1	1	1	1	0	0	0	0	0	0	1	1	1	1	0	0
Lâmpadas - Corredor	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0
Lâmpadas - Banheiros	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	1	1	0	0	1	0
Ar condicionado - Sala1	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	1	1	1	1	0	1	0	1	0
Ar condicionado - Sala2	0	0	0	0	0	0	1	1	0	0	1	0	0	0	1	0	1	0	0	0	0	0	1	1
Ar condicionado - Sala3	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	1	0	0	0	1	0	1	0
Ar condicionado - Sala4	0	0	0	0	0	0	1	1	1	1	1	1	0	0	1	0	1	0	1	0	1	0	0	0
Ar condicionado - Sala de reunião	0	0	0	0	0	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Ar condicionado - Administração	0	0	0	0	0	1	0	1	0	1	1	1	0	0	1	0	0	1	0	0	0	0	0	0
Ar condicionado - Auditório	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	0

Figura 11 - Agendamento dos dispositivos para o nível de conforto 0.8

Fonte: Autora (2022)

Observando os agendamentos é possível notar que o nível 0.5 seria o nível mais indicado, pois não há tantas interrupções no funcionamento das cargas e torna o sistema mais

praticável e condizente com a realidade, ao mesmo tempo em que reduz o custo com eletricidade em 13.2% e a demanda de energia em horários de pico.

3.5.3 Comparação com o CPLEX

O BPSO foi submetido a dez execuções para cada uma das quatro instâncias e foram registradas as melhores soluções da metaheurística para cada instância em dez rodadas e o tempo de processamento (T(s)), apresentado na Tabela 5. Além disso, também foram calculados os menores *gaps* percentuais (MGP) e os *gaps* médios percentuais (GMP) do BPSO em relação a solução ótima de cada instância, apresentado na Tabela 6. O menor *gap* percentual é dado pela diferença entre a melhor solução encontrada pela metaheurística em dez rodadas e o valor ótimo obtido pelo CPLEX, dividido pelo ótimo, em cada instância. No *gap* médio percentual é utilizado a média das soluções obtidas nas dez rodadas ao invés da melhor solução.

Como as funções conforto e restrição estão associadas a pesos de nivelamento para o cálculo da função objetivo, foram observados na comparação tanto os valores obtidos para a função objetivo quanto para a função consumo. Visto que em alguns testes o BPSO pode admitir um pequeno valor de desconforto e aceita resultados fora da região factível, aumentando o resultado da função objetivo.

Tabela 5 - Melhor solução obtida com o BPSO e com o CPLEX

Instância	CPLEX		BPSO	
	Melhor	T(s)	Melhor	T(s)
1	3,60	0,33	3,60	52,03
2	6,74	0,45	6,74	216,01
3	12,12	0,53	12,50	522,77
4	20,56	0,84	29,05	974,27

Fonte: Autora (2022).

Analisando a melhor solução obtida pelo BPSO em dez rodadas pode-se observar que o algoritmo tem capacidade de encontrar a solução ótima ou valores bem próximos, porém com um tempo de processamento superior ao CPLEX e que aumenta conforme aumenta o número de dispositivos. Esse tempo se deve, principalmente, a fatores relacionados a construção do código em Python e ao compilador utilizado e, provavelmente, devido ao método de

penalização das restrições. Por aceitar soluções inviáveis com penalidade, o algoritmo permanece uma parte da busca em regiões não factíveis até que encontre a região factível.

Tabela 6 - Gaps percentuais para a função objetivo e para a função consumo

Instância	Função Objetivo		Função Consumo	
	MGP(%)	GMP(%)	MGP(%)	GMP(%)
1	0,0	0,0	0,0	0,0
2	0,0	2,40	0,0	2,40
3	3,10	33,04	3,10	5,54
4	41,29	260,83	27,39	17,15

Fonte: Autora (2022).

Na Tabela 6 é possível notar o quanto a penalidade tem influência na função objetivo, visto que conforme aumenta o número de dispositivos, a metaheurística começa a apresentar resultados com valores maiores de desconforto ou a admitir soluções não factíveis. Dessa forma, o valor da função objetivo sofre uma penalidade e mostra a necessidade de reajustar os pesos P_{conf} e P_{rest} para que o algoritmo encontre o ótimo para determinada instância. Essa análise pode ser observada pelo aumento considerável do GMP da função objetivo em relação a função consumo conforme aumenta o número de dispositivos.

Ao observar o MGP da função objetivo e da função consumo vemos que, apesar do MGP aumentar, o algoritmo continua com a capacidade de obter o ótimo ou soluções próximas dentro das dez rodadas, pois a porcentagem de aumento é mais baixa, principalmente na função consumo.

Com isso, nota-se que o BPSO tem uma boa capacidade de resolução do problema, mas é necessário realizar outras abordagens de escrita do código de forma a acelerar a execução do algoritmo. Outra forma de acelerar o código seria alterar o compilador do *Python* utilizando o interpretador *PyPy* ou a biblioteca *Numba*, que melhoram a execução do código *Python* ou alterar o código para a linguagem C. Nota-se também a necessidade de alterar a forma como o algoritmo lida com as restrições para que sua performance se aproxime mais ainda do CPLEX.

Os testes com as instâncias foram realizados novamente utilizando a biblioteca *Numba* que é um compilador JIT (do inglês *Just-in-Time*) que traduz um subconjunto do código *Python* para a linguagem de máquina otimizada em tempo de execução. Com isso, foram obtidos tempos de execução significativamente menores para o BPSO em cada instância, conforme

Tabela 7, mostrando a influência que a adoção dessas técnicas pode ter no desempenho do código.

Tabela 7 - Tempo de execução utilizando a biblioteca *Numba*

Instância	1	2	3	4
T(s)	10,64	54,38	136	258,42

Fonte: Autora (2022).

Para melhor entendimento de como é realizado o gerenciamento das cargas podemos observar o agendamento obtido por uma instância menor (instância 2, Tabela 8) com solução ótima encontrada pelos dois métodos, Figuras 12 e 13.

Tabela 8 – Dispositivos da instância 2 e suas características

Dispositivo	Qnt.	Pot	Ciclos	H	Hmin	Hmax	Tipo	γ
Lâmpadas1	2	0,27	1	8	8	22	1	2
Lâmpadas2	1	0,27	1	7	8	17	1	2
Lâmpadas3	2	0,27	1	3	17	23	2	1
Ar condicionado1	1	2,17	1	8	8	22	1	2
Ar condicionado2	1	2,17	1	7	8	17	1	2
Ar condicionado3	1	1,63	2	3	8	17	2	2

Fonte: Autora (2022).

Apesar de encontrarem o mesmo valor final, há alguns pontos onde a carga tem um planejamento diferente em cada método devido ao custo da tarifa ser o mesmo em pontos diferentes e por estarem dentro do horário de conforto definido pelo usuário.

Dispositivos	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	
Lâmpadas 1	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	0	1	0	0	0	1	0	0	
Lâmpadas 2	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	1	0	0	0	0	0	0	0	0
Lâmpadas 3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	
Ar condicionado 1	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	0	1	0	0	0	0	1	0	
Ar condicionado 2	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	0	1	0	0	0	0	0	0	0
Ar condicionado 3	0	0	0	0	0	0	0	0	1	1	1	0	0	0	1	1	1	0	0	0	0	0	0	0	0

Figura 12 - Agendamento dos dispositivos pelo BPSO

Fonte: Autora (2022).

Dispositivos	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
Lâmpadas 1	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	1	0	0	0	0	1	0	0
Lâmpadas 2	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	0	1	0	0	0	0	0	0
Lâmpadas 3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1
Ar condicionado 1	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	0	0	0	0	0	1	1	0
Ar condicionado 2	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	0	1	0	0	0	0	0	0
Ar condicionado 3	0	0	0	0	0	0	0	0	0	1	1	1	0	0	1	1	1	0	0	0	0	0	0	0

Figura 13 - Agendamento dos dispositivos pelo CPLEX

Fonte: Autora (2022).

Todos os dispositivos atendem o tempo de duração mínimo informado na Tabela 7 e a restrição de horário de almoço. Além disso, também é respeitada a restrição de carga não interrompível dos dispositivos Lâmpadas 3 e Ar condicionado 3, onde ambas têm tempo de duração de 3 horas após acionadas. Todas as cargas também estão dentro dos limites de conforto definidos pelo usuário e o consumo é reduzido no horário de crítico entre as 16h e 22h.

3.6 Considerações finais

Considerando um modelo complexo como o gerenciamento de energia do Polo de Inovação de Campos dos Goytacazes, os resultados mostram que o método de penalização utilizado para lidar com as restrições e a transformação do problema multiobjetivo em um mono-objetivo através de pesos contribuem de maneira efetiva na aplicação do BPSO em um cenário real de larga escala. Porém, quando comparado com o CPLEX em diferentes instâncias nota-se um tempo de execução muito alto e a necessidade de ajustar os pesos das funções de acordo com a quantidade de dispositivos para que a metaheurística encontre o ótimo.

Apesar das melhorias necessárias, o algoritmo é eficiente em gerenciar o consumo de energia elétrica através do planejamento de operação dos dispositivos encontrados no PICG, minimizando os custos com eletricidade frente às variações tarifárias enquanto reduz também o desconforto do consumidor e a demanda de energia em horários de pico. Os objetivos são alcançados levando em considerações um cenário de otimização real e complexo, contendo geração de energia renovável, diferentes modos de operação dos dispositivos e as preferências do consumidor de acordo com o nível de conforto desejado, sendo essa uma característica importante para a aderência a programas de resposta à demanda.

Com isso, as principais contribuições deste trabalho são: a criação de um modelo matemático representando o sistema do PICG e suas restrições, a implementação da solução do problema de gerenciamento de energia utilizando a metaheurística Otimização por Enxame de Partículas Binário aplicada na modelagem criada; um sistema de gerenciamento que busca

equilíbrio entre conforto e consumo quando aplicado a Tarifa Horária Branca de forma contribuir para o achatamento da demanda em horários críticos sem risco de prejuízo ao usuário; possibilidade de informar características dos dispositivos e preferência do usuário.

Para trabalhos futuros, a adoção de abordagens que reduzem o tempo de processamento do código pode melhorar sua performance nesse sentido. Recomenda-se também a comparação com outros métodos para lidar com as restrições, de forma a tornar o algoritmo mais próximo do desempenho do CPLEX e reduzir seu tempo de processamento. Além disso, a integração sensores de medição de temperatura e iluminação em conjunto com dados climáticos e restrições de acionamento baseadas nesses fatores podem potencializar a implementação do algoritmo a cenários reais de um campus inteligente.

3.7 Referências

ANEEL. Resolução Normativa nº 733, de 6 de setembro de 2016. . 2016.

ANEEL. **Tarifa Branca - ANEEL**. Disponível em: <<https://www.aneel.gov.br/tarifa-branca>>. Acesso em: 1 fev. 2022.

AHMED, A. et al. Swarm Intelligence Based Home Energy Management Controller Under Dynamic Pricing Scheme. In: BAROLLI, L.; XHAFA, F.; CONESA, J. (Eds.). . **Advances on Broad-Band Wireless Computing, Communication and Applications**. Lecture Notes on Data Engineering and Communications Technologies. Cham: Springer International Publishing, 2018. v. 12p. 256–266.

CABRITA, C. L.; MONTEIRO, J. M.; S. CARDOSO, P. J. **Improving Energy Efficiency in Smart-Houses by Optimizing Electrical Loads Management**. 2019 1st International Conference on Energy Transition in the Mediterranean Area (SyNERGY MED). **Anais...** In: 2019 1ST INTERNATIONAL CONFERENCE ON ENERGY TRANSITION IN THE MEDITERRANEAN AREA (SYNERGY MED). maio 2019.

CARROLL, C. W. The Created Response Surface Technique for Optimizing Nonlinear, Restrained Systems. **Operations Research**, v. 9, n. 2, p. 169–184, abr. 1961.

COURANT, R. Variational methods for the solution of problems of equilibrium and vibrations. **Bulletin of the American Mathematical Society**, v. 49, n. 1, p. 1–23, 1943.

EBERHART, R.; KENNEDY, J. A New Optimizer Using Particle Swarm Optimization. In: **Proceedings of the Sixth International Symposium on Micro Machine and Human**

Science, Nagoya Municipal Industrial Research Institute. Piscataway, NJ: IEEE Service Center, 1995. p. 39–43.

FIACCO, A. V.; MCCORMICK, G. P. Extensions of SUMT for Nonlinear Programming: Equality Constraints and Extrapolation. **Management Science**, v. 12, n. 11, p. 816–828, jul. 1966.

GIL, A. C. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 2009.

HOMAIFAR, A.; QI, C. X.; LAI, S. H. Constrained Optimization Via Genetic Algorithms. **SIMULATION**, v. 62, n. 4, p. 242–253, abr. 1994.

HUANG, Y.; TIAN, H.; WANG, L. Demand response for home energy management system. **International Journal of Electrical Power & Energy Systems**, v. 73, p. 448–455, dez. 2015.

JAVAID, N. et al. An Intelligent Load Management System with Renewable Energy Integration for Smart Homes. **IEEE Access**, p. 14, 2016.

KENNEDY, J. The particle swarm: Social adaptation of knowledge. In: **Proceedings of 1997 IEEE International Conference on Evolutionary Computation (ICEC '97)**. Piscataway, N.J: IEEE, 1997.

KENNEDY, J.; EBERHART, R. Particle Swarm Optimization. In: **Proceedings of International Conference on Neural Networks, University of Western Australia**. Piscataway, NJ: [s.n.].

KENNEDY, J.; EBERHART, R. A Discrete Binary Version of the Particle Swarm Algorithm. In: **Computational cybernetics and simulation: Proceedings of International Conference on Systems, Man and Cybernetics**. New York, NY: IEEE, 1997.

KENNEDY, J. F.; EBERHART, R. C.; SHI, Y. **Swarm intelligence**. San Francisco: Morgan Kaufmann Publishers, 2001.

MEZURA-MONTES, E.; COELLO, C. A. C. An empirical study about the usefulness of evolution strategies to solve constrained optimization problems. **International Journal of General Systems**, v. 37, n. 4, p. 443–473, ago. 2008.

NAZ, M. et al. **Efficient Power Scheduling in Smart Homes Using Meta Heuristic Hybrid Grey Wolf Differential Evolution Optimization Technique**. 2018 IEEE 32nd International Conference on Advanced Information Networking and Applications (AINA). **Anais...** In: 2018

IEEE 32ND INTERNATIONAL CONFERENCE ON ADVANCED INFORMATION NETWORKING AND APPLICATIONS (AINA). Krakow, Poland: IEEE, maio 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8432300/>>. Acesso em: 30 set. 2021

NGUYEN, T.-H. et al. Bio-Inspired Approaches for Smart Energy Management: State of the Art and Challenges. **Sustainability**, v. 12, n. 20, p. 8495, 15 out. 2020.

SABOOR, A. et al. **Home Energy Management in Smart Grid Using Evolutionary Algorithms**. 2018 IEEE 32nd International Conference on Advanced Information Networking and Applications (AINA). **Anais...** In: 2018 IEEE 32ND INTERNATIONAL CONFERENCE ON ADVANCED INFORMATION NETWORKING AND APPLICATIONS (AINA). Krakow: IEEE, maio 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8432356/>>. Acesso em: 30 set. 2021

SHAFIQ, S. et al. **An Approach Towards Efficient Scheduling of Home Energy Management System Using Backtracking Search Optimization and Tabu Search**. 2018 32nd International Conference on Advanced Information Networking and Applications Workshops (WAINA). **Anais...** In: 2018 32ND INTERNATIONAL CONFERENCE ON ADVANCED INFORMATION NETWORKING AND APPLICATIONS WORKSHOPS (WAINA). Krakow: IEEE, maio 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8418076/>>. Acesso em: 30 set. 2021

SILVA, E. L.; MENEZES, E. M. **Metodologia da Pesquisa e Elaboração de Dissertação**. 4. ed. Florianópolis: UFSC, 2005.

REFERÊNCIAS

ANEEL. Resolução Normativa nº 733, de 6 de setembro de 2016. . 2016.

ANEEL. **Tarifa Branca - ANEEL**. Disponível em: <<https://www.aneel.gov.br/tarifa-branca>>. Acesso em: 1 fev. 2022.

KENNEDY, J. The particle swarm: Social adaptation of knowledge. In: **Proceedings of 1997 IEEE International Conference on Evolutionary Computation (ICEC '97)**. Piscataway, N.J: IEEE, 1997.

Numba: A High Performance Python Compiler. Disponível em: <<https://numba.pydata.org/>>. Acesso em: 30 mar. 2022.