

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**ALGORITMO HÍBRIDO DE OTIMIZAÇÃO POR
ENXAME DE PARTÍCULAS APLICADO AO
GERENCIAMENTO DE CARGAS RESIDENCIAIS**

DIEGO LUIZ CAVALCA

ORIENTADOR: PROF. DR. RICARDO AUGUSTO SOUZA FERNANDES

São Carlos - SP
Março/2018

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**ALGORITMO HÍBRIDO DE OTIMIZAÇÃO POR
ENXAME DE PARTÍCULAS APLICADO AO
GERENCIAMENTO DE CARGAS RESIDENCIAIS**

DIEGO LUIZ CAVALCA

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação, área de concentração: Inteligência Artificial

Orientador: Dr. Ricardo Augusto Souza Fernandes

São Carlos - SP

Março/2018



Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

Folha de Aprovação

Assinaturas dos membros da comissão examinadora que avaliou e aprovou a Defesa de Dissertação de Mestrado do candidato Diego Luiz Cavalca, realizada em 09/03/2018:

Prof. Dr. Ricardo Augusto Souza Fernandes
UFSCar

Prof. Dr. Guilherme Guimarães Lage
UFSCar

Prof. Dr. Luiz Carlos Pereira da Silva
UNICAMP

*Dedico este trabalho as pessoas mais importantes de minha vida, meus pais,
Luiz e Sheila, minha irmã Viviane, à minha noiva Ana Carla e aos meus
eternos amigos, Junior e Luthor.*

AGRADECIMENTO

Agradeço primeiramente a Deus por todos os dias de vida, pela força, proteção e sabedoria que me concedeu ao longo desta jornada.

Sou grato a minha família por todo o apoio e carinho, a qual sempre me dá forças para enfrentar cada obstáculo. Em especial aos meus amados pais que, com amor e dedicação, nunca mediram esforços pela minha educação. Serei eternamente grato por me oferecerem a oportunidade de estudar e me fornecerem a base necessária para a realização deste Mestrado.

A minha querida noiva Ana Carla, pelo amor e companheirismo em todos os momentos, os quais foram de fundamental importância para enfrentar com entusiasmo este desafio.

Sou grato a todos os colegas do departamento pelos momentos vividos, principalmente naqueles que mais precisei de alguma forma de ajuda.

Agradeço ao meu orientador, Ricardo A. S. Fernandes, pela oportunidade concedida. Obrigado pela confiança, paciência e conhecimento compartilhado. Contigo me tornei mais sábio, e sem a sua pessoa, seria impossível desenvolver este trabalho.

A todos professores do Departamento de Computação, responsáveis por minha formação. Agradeço também ao CNPq pelo apoio financeiro.

Todos, sem exceção, foram fundamentais para o desenvolvimento deste trabalho.

Os vitoriosos são aqueles que receberam oportunidades e tiveram força e presença de espírito para agarrá-las.

Malcolm Gladwell

RESUMO

O gerenciamento da energia elétrica pelo lado da demanda é uma estratégia útil e necessária no contexto das *Smart Grids*, uma vez que permite reduzir o consumo de energia em períodos de maior consumo da rede, visando garantir a confiabilidade do sistema e minimizando o desperdício de recursos. Logo, a eficiência da produção e consumo de energia é uma característica fundamental neste contexto, e métodos de otimização são altamente relevantes, sendo uma parte crucial do planejamento, operação e controle de sistemas de energia. Neste trabalho, uma nova abordagem do algoritmo de enxame de partículas é proposta para a resolução em tempo viável do planejamento de operações de cargas em uma residência inteligente, tendo como objetivo mitigar problemas relacionados à alta dimensionalidade e à presença de restrições, inerentes a problemas neste domínio. Assumindo um robusto modelo matemático, os resultados de simulações computacionais mostram que a abordagem proposta, mesmo quando comparada à métodos alternativos, contribui de maneira significativa para a redução dos custos com energia elétrica frente a variações tarifárias, bem como minimiza a utilização de cargas residenciais em horários de pico para um grupo de consumidores, obtendo soluções otimizadas em tempo adequado, exprimindo a aplicabilidade do algoritmo proposto.

Palavras-chave: Otimização, Redes Inteligentes, Resposta à Demanda, Meta-heurísticas, Enxame de Partículas.

ABSTRACT

Demand side power management and a useful solution and guarantee in the context of Smart Grids, since it allows to reduce energy consumption in periods of greater network consumption, aiming to ensure system reliability and minimize resource wastage. Thus, production efficiency and energy consumption are a key feature in this context, and optimization methods are highly relevant, being a crucial part of the planning, operation and control of energy systems. In this work, a new particle swarm optimization algorithm approach is proposed for the feasible time resolution of the load operation planning in a smart home, aiming to mitigate problems related to the high dimensionality and the presence of constraints, inherent problems in this field. Assuming a robust mathematical model, the results of the computational simulations carried out show that the proposed approach, even when compared to alternative methods, contributes significantly to reduction of energy costs in relation to tariff variations, as well as minimizing the use of residential loads at peak times for a group of consumers, obtaining optimized solutions in adequate time, expressing to the applicability of the proposed algorithm.

Keywords: Optimization, Smart Grids, Demand Response, Metaheuristics, Particle Swarm.

LISTA DE FIGURAS

Figura 1: Atividades para o Gerenciamento pelo Lado da Demanda.	21
Figura 2: Estratégias de Gerenciamento de Carga.	24
Figura 3: Estruturas de Programas de Resposta à Demanda.	26
Figura 4: Representação da variação de preço da energia ao longo do dia nos programas de tarifação: (a) <i>Time-of-Use</i> , (b) <i>Real-Time Pricing</i> e (c) <i>Critical-Peak Pricing</i>	29
Figura 5: Evolução do número de publicações por ano.	41
Figura 6: Evolução histórica de publicações sobre cada programa de DR baseado em tarifas/preços.	43
Figura 7: Países mais produtivos na área de <i>DR</i> , em relação aos programas baseados em tarifas/preços.	44
Figura 8: Arquitetura do HEMS.	49
Figura 9: Comportamento Exploratório do Enxame Rumo à Solução Otimizada.	59
Figura 10: Fluxograma da metodologia adotada.	71
Figura 11: Tarifa utilizada no problema de otimização.	75
Figura 12: Fluxograma da abordagem SGC-PSO proposta.	76
Figura 13: Mecanismo de correção pelo gradiente aplicado em um problema bidimensional.	78
Figura 14: Agendamento de cargas da melhor solução obtida pelo PN-PSO.	90
Figura 15: Dispersão dos Resultados dos Diferentes Modos de Atualização.	92
Figura 16: Convergência das Melhores Soluções de cada Modo de Atualização.	93
Figura 17: Planejamento de Cargas Otimizado para Residência.	94
Figura 18: Variação Tarifária do Planejamento Otimizado.	95
Figura 19: Agendamento de Carga Otimizado Proposto pelo SGC-PSO.	97

LISTA DE TABELAS

Tabela 1: Indicadores gerais obtidos em relação ao conjunto de dados.	40
Tabela 2: Publicações por programas de DR baseados em tarifas/preços.	42
Tabela 3: Número de publicações sobre os programas de DR baseados em tarifas/preços por ano.....	43
Tabela 4: Números de publicações sobre programas de DR baseados em tarifas/preços por país.....	45
Tabela 5: Números de Citações por País.	46
Tabela 6: Parâmetros e restrições associados às cargas da residência.	72
Tabela 7: Classificação das cargas de acordo com o tipo de operação.	74
Tabela 8: Parâmetros operacionais da bateria residencial.	74
Tabela 9: Configurações dos PSOs analisados.	84
Tabela 10: Cenário residencial da comparação SGC-PSO <i>versus</i> CPLEX.	86
Tabela 11: Resumo comparativo entre SGC-PSO e CPLEX.	87
Tabela 12: Resumo de desempenhos do SGC-PSO e PN-PSO.	88
Tabela 13: Melhores soluções obtidas pelo SGC-PSO e PN-PSO.....	89
Tabela 14: Resultados para cada modo de atualização do SGC-PSO.....	91

LISTA DE ABREVIATURAS E SIGLAS

BFO	<i>Bacterial Foraging Optimization</i>
BPSO	<i>Binary Particle Swarm Optimization</i>
CPP	<i>Critical-Peak Pricing</i>
DR	<i>Demand Response</i>
DSM	<i>Demand Side Management</i>
ECS	<i>Energy Consumption Scheduler</i>
EDE	<i>Enhanced Differential Evolution</i>
GA	<i>Genetic Algorithm</i>
GW	<i>Gigawatt</i>
HEMS	<i>Home Energy Management System</i>
HSA	<i>Harmony Search Algorithm</i>
IBDR	<i>Incentive Based Demand Response</i>
MILP	<i>Mixed-Integer Linear Programming</i>
MINLP	<i>Mixed-Integer Non-Linear Programming</i>
LAN	<i>Local Area Network</i>
LDW-PSO	<i>Linear Decreasing Weight Particle Swarm Optimization</i>
PAR	<i>Peak to Average Ratio</i>
PBDR	<i>Price Based Demand Response</i>
PHEV	<i>Plug-in Hybrid Electric Vehicle</i>
PSO	<i>Particle Swarm Optimization</i>
RTP	<i>Real-Time Pricing</i>
SEP	<i>Sistema Elétrico de Potência</i>
SG	<i>Smart Grid</i>
SGC-PSO	<i>Stochastic Gradient Correction PSO</i>
SOC	<i>State of charging</i>
TOU	<i>Time-of-Use Pricing</i>
WDO	<i>Wind-Driven Optimization</i>

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO.....	13
1.1 Definição do Problema de Pesquisa	13
1.2 Hipótese	15
1.3 Objetivos	17
1.4 Organização do Trabalho.....	18
CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA	20
2.1 Gerenciamento de Energia Elétrica pelo Lado da Demanda	20
2.2 <i>Demand Response</i>	22
2.3 Classificação dos Programas de <i>Demand Response</i>	25
2.3.1 Programas Baseados em Incentivos.....	25
2.3.2 Programas Baseados em Tarifas/Preços.....	27
2.4 Otimização de <i>Demand Response</i>	30
2.5 Gestão de Cargas Residenciais com Meta-heurísticas	32
2.6 Modelagem do Problema de Otimização de DR.....	34
CAPÍTULO 3 - ANÁLISE BIBLIOMÉTRICA DA ÁREA DE <i>DEMAND RESPONSE</i> 38	
3.1 Indicadores Gerais	40
3.2 Evolução Histórica de Publicações	41
3.3 Publicações por Tipo de Programa de DR Baseado em Tarifas/Preço	42
3.4 Análise das Publicações por País	44
CAPÍTULO 4 - MODELAGEM DO PROBLEMA E MÉTODOS DE OTIMIZAÇÃO.. 48	
4.1 Modelo Matemático	48
4.1.1 Função Objetivo	50
4.1.2 Restrições de Cargas.....	50
4.2 Heurísticas	55
4.3 Meta-heurísticas	55
4.4 Otimização por Enxame de Partículas	57
4.4.1 Fundamentos	57
4.4.2 PSO com Fator de Inércia Decrescente.....	60

4.4.3 PSO com Fator de Construção	61
4.4.4 PSO com Inércia Individualizada e Adaptativa	62
4.4.5 PSO Binário.....	63
4.5 Aplicação em Problemas Complexos.....	65
4.5.1 Problemas com Restrições	65
4.5.1.1 Penalização da Função Objetivo.....	66
4.5.1.2 Ajuste pelo Gradiente das Restrições	67
4.5.2 Viés Estrutural	69
CAPÍTULO 5 - METODOLOGIA PROPOSTA.....	71
5.1 Simulações.....	72
5.2 Abordagem Proposta para Aplicação do PSO	75
5.2.1 Representação do Indivíduo	76
5.2.2 Mecanismos de Controle de Viabilidade	77
5.2.2.1 Utilização da Bateria	77
5.2.2.2 Agendamentos Estocásticos dos Equipamento Eletrodomésticos	79
5.2.3 Atualização do Enxame.....	80
5.2.3.1 Ranking de Soluções	81
5.2.4 Critérios de Parada	83
5.3 Estudo de caso.....	83
CAPÍTULO 6 - RESULTADOS	85
6.1 Comparação com o CPLEX	85
6.2 Comparação com o PN-PSO	87
6.3 Variações no Modo Atualização do Enxame no SGC-PSO	90
6.4 Análises Adicionais do SGC-PSO	94
CAPÍTULO 7 - CONSIDERAÇÕES FINAIS	98
REFERÊNCIAS.....	99
APÊNDICE A	106

Capítulo 1

INTRODUÇÃO

A maioria dos setores industriais, conforme GELLINGS (1985), não trata a demanda de seus produtos como um fenômeno estático. Logo, é esperada uma reação do cliente – quer seja positiva ou negativa – diante de uma variação no preço de um produto. Tal comportamento rege o mercado consumidor em escala global, potencializando o desenvolvimento de estratégias a fim de melhorar a comercialização de bens de qualquer natureza. Segundo o DOE (2006), o setor de energia elétrica cresce em função do crescimento populacional e econômico. Assim, a extensão da atividade de gestão de recursos das concessionárias de energia elétrica para o lado da demanda torna-se uma alternativa plausível na otimização do uso do sistema elétrico. Neste cenário, o consumidor é integrado ao planejamento, assumindo um papel ativo nos programas de *Demand Response*. Diante deste contexto, assumindo que a demanda dos consumidores pode ser alterada de modo deliberado pela cooperação mútua entre a concessionária e o consumidor, abre-se uma nova dimensão no planejamento e operação do Sistema Elétrico de Potência (SEP) (GELLINGS, 2009).

1.1 Definição do Problema de Pesquisa

O aumento da demanda por energia elétrica e os recursos naturais limitados exigem desenvolvimento de estratégias sustentáveis a fim de manter a produção industrial. A eficiência em toda a cadeia produtiva é uma característica significativa

que contribui diretamente com essa sustentabilidade. Dessa forma, métodos adequados de produção e consumo de energia se tornam altamente relevantes.

Devido às novas tecnologias, a infraestrutura dos sistemas de energia elétrica vem evoluindo consideravelmente ao longo dos anos, viabilizando o surgimento de uma rede altamente interconectada, a qual conta com dispositivos elétricos e de telecomunicação (SIANO, 2014). Chamada *Smart Grid* (SG), esta rede de energia elétrica é construída com base em comunicação digital bidirecional, que viabiliza a troca mútua de informações entre todos os agentes envolvidos no sistema e garante meios permitam a operação segura e eficiente da geração, transmissão e distribuição de energia elétrica (AGHAEI e ALIZADEH, 2013; SIANO, 2014).

Um dos aspectos mais importantes de uma *Smart Grid*, e que visa a otimização do uso de energia, é o gerenciamento pelo lado da demanda (DSM, do inglês *Demand Side Management*), que representa um mecanismo que fornece equilíbrio entre demanda e oferta, onde os consumidores são encorajados a mudar seu padrão de consumo de energia em horários de pico (PALENSKY e DIETRICH, 2011). A *Demand Response* (DR) e o gerenciamento de carga¹ são as duas principais estratégias do DSM, nas quais o foco é o gerenciamento eficiente da energia consumida a fim de reduzir as chances de possíveis condições de operação crítica ou de emergência do sistema elétrico devido à concentração de demanda (VARDAKAS e ZORBA, 2015).

Neste cenário, os consumidores podem gerenciar o consumo de energia elétrica de maneira adequada, definindo o melhor horário para a utilização de cada carga de acordo com diversos fatores, como, por exemplo, a variação de preço da energia. Ainda, no caso de consumidores residenciais, é possível adequar o gerenciamento de suas cargas visando respeitar as premissas de utilização e conforto.

O pleno gerenciamento de cargas não é uma tarefa trivial, pois deve levar em consideração os objetivos da concessionária e de seus consumidores, suavizando a curva de carga e reduzindo o custo da energia consumida, respectivamente. Diante desta complexidade, as atividades de DR necessitam de técnicas de agendamento eficientes e automatizadas que apoiem as tomadas de decisão dos consumidores. Tais técnicas devem levar em consideração, além dos fatores já citados, as características das cargas que, segundo HAIDER, SEE e ELMENREICH (2016),

¹ Também tratado como agendamento de carga na literatura correlata.

podem ser classificadas em dois tipos. O primeiro tipo é de carga móvel, que compreende as cargas cuja demanda de energia pode ser agendada em diferentes horários do dia, como, por exemplo, uma máquina de lavar roupas. O segundo tipo é a carga fixa, que compreende aquelas cujo funcionamento fica restrito a um específico horário (definido pelo consumidor), como, por exemplo, cargas de iluminação. De acordo com esses tipos de carga, uma técnica de agendamento precisa deslocar o máximo possível as cargas de forma a permitir que os consumidores reduzam suas contas de energia e a concessionária equilibre os níveis de consumo do sistema, tornando vantajosa a implementação de programas de *Demand Response* (BATCHU e PINDORIYA, 2015).

A importância do gerenciamento de carga torna-se evidente quando analisado o atual panorama elétrico. Segundo ALBERINI e FILIPPINI (2011), aproximadamente 30% a 40% do consumo de energia elétrica ao redor do mundo é oriundo de consumidores residenciais, os quais contribuem significativamente para o pico de demanda sazonal e diário (HE *et al.*, 2012). Estima-se ainda que, visando garantir a segurança do sistema, 20% da capacidade de geração de energia e parte dos investimentos em infraestrutura de distribuição são destinadas para atender a demanda de pico, que ocorre por aproximadamente apenas 5% do tempo (BASSAMZADEH *et al.*, 2014).

Portanto, conforme HAIDER, SEE e ELMENREICH (2016), a adoção de um método eficiente de otimização do consumo de energia, combinado a uma infraestrutura de comunicação adequada, possui um papel de extrema importância na obtenção da programação de operação otimizada das cargas dos consumidores, resultando, deste modo, em benefícios concretos para todos os participantes do sistema elétrico.

1.2 Hipótese

Conforme supracitado, o gerenciamento de cargas nas SGs representa benefícios diretos para todos os participantes do sistema elétrico, viabilizando a minimização do custo da eletricidade para o consumidor e a redução da razão entre

pico e média de demanda (PAR, do inglês *Peak to Average Ratio*), sendo este um benefício direto para a concessionária.

Muitas estratégias de DSM apoiadas em modelos matemáticos e técnicas de otimização computacional foram propostas nos últimos anos visando o gerenciamento eficiente de cargas (BATCHU e PINDORIYA, 2015). Todavia, o balanço entre a obtenção de uma solução otimizada e a complexidade computacional exigida para este fim representa um dos maiores desafios na otimização da DR (BEAUDIN e ZAREIPOUR, 2017). No setor residencial, o qual será considerado neste trabalho, o planejamento (escalonamento das cargas) realizado por técnicas de otimização deve considerar um grande conjunto de parâmetros, contemplando, por exemplo, o valor da energia elétrica, características de funcionamento das cargas, o padrão de vida dos consumidores, a geração de energia fotovoltaica e a presença de dispositivos de armazenamento de energia.

Assim, a avaliação de desempenho das técnicas de otimização revela-se de extrema importância para a implementação de programas de DR que visem maximizar os benefícios de concessionárias e consumidores residenciais. Algumas abordagens são propostas na literatura para gerenciar o consumo de energia, como programação matemática e/ou meta-heurísticas.

Em ZAFAR *et al.* (2017), os autores apresentaram uma ampla gama de trabalhos nos quais métodos de programação matemática – como otimização linear, linear inteira mista, não linear inteira mista e programação convexa – são utilizados como técnicas de otimização para o gerenciamento de carga, visando minimizar os custos de consumo de energia.

De acordo com OGWUMIKE, SHORT e ABUGCHEM (2016), técnicas de programação matemática e dinâmica também podem ser aplicadas com sucesso ao problema de gerenciamento de carga em SG. Porém, essas técnicas, dependendo do modelo matemático adotado para o processo de otimização, não possuem a capacidade de lidar com um grande número de cargas residenciais, limitando a utilização destas em cenários reais. Neste contexto, VALLE *et al.* (2008) citam que estas abordagens são suscetíveis à “maldição da dimensionalidade” na resolução deste tipo de problema, fenômeno que denota o aumento do esforço computacional à medida que o tamanho do problema cresce. HUANG, TIAN e WANG (2015) argumentam ainda que outra desvantagem de tais técnicas, considerando pacotes

comerciais como o CPLEX, é o fato de apresentarem requisitos computacionais que dificultam sua implementação em dispositivos embarcados, como medidores inteligentes.

Devido às dificuldades de algoritmos de programação matemática e dinâmica encontrarem soluções viáveis para esses problemas em condições reais (dentro de tempos factíveis), técnicas de computação evolutiva emergiram com grande eficiência em aplicações de DSM. Conforme descrevem LOGENTHIRAN *et al.* (2012) e JAVAID *et al.* (2017), a fim de superar as limitações das técnicas previamente mencionadas, as meta-heurísticas se colocam como métodos de otimização eficientes para o gerenciamento de energia em larga escala nas SGs, contemplando flexibilidade de implementação e parâmetros fáceis de gerenciar. Nesta classe de técnicas, o algoritmo de Otimização por Enxame de Partículas (PSO, do inglês *Particle Swarm Optimization*) vem sendo explorado amplamente e aplicado em diversos problemas de *Demand Response*, conforme mostram os trabalhos de FARIA *et al.* (2011), LOGENTHIRAN, SRINIVASAN e PHYU (2015), REMANI, JASMIN e AHAMED (2015), ABEDIN *et al.* (2015) e CHALISE *et al.* (2016).

Portanto, este trabalho busca investigar a aplicação do algoritmo PSO no problema de DSM, visando avaliar o desempenho deste método quando aplicado em otimização de um cenário residencial complexo e de larga-escala, considerando particularidades e informações do contexto brasileiro de energia elétrica.

1.3 Objetivos

Este trabalho tem como objetivo principal propor a resolução de um problema de DR por meio da implementação de uma estratégia de DSM, a qual, baseada em uma robusta modelagem matemática, otimize o planejamento de operação de cargas de uma típica residência brasileira empregando-se o algoritmo PSO. Neste sentido, é proposta uma versão híbrida do mesmo, que contempla mecanismos que delimitam o movimento dos indivíduos dentro do espaço factível, realizando um ajuste pelo gradiente das restrições do modelo e de amostragem estocástica em função da tarifa de energia elétrica. Assim, é obtido o agendamento otimizado de operação das cargas, respeitando um elevado número de restrições, as quais compreendem os

desejos e necessidades dos residentes, características de funcionamento das cargas e a flutuação do preço da energia. Tal resolução ainda leva em consideração a presença de dispositivos de armazenamento de energia elétrica (banco de bateria), a qual possui restrições próprias de funcionamento e de vida útil que devem ser consideradas. Logo, a obtenção deste agendamento não é uma tarefa trivial, uma vez que a minimização do custo da energia ocorre em função de um cenário de alta complexidade e de larga escala, e que deve ser resolvido dentro de um tempo aceitável e factível de implementação.

Visando quantificar a eficiência da proposta apresentada neste trabalho, será realizada uma análise comparativa sobre seu desempenho frente a solução obtida pelo pacote de solução exata CPLEX e em relação às abordagens clássicas do algoritmo PSO na resolução do problema elucidado. Dentre as versões clássicas consideradas, são implementadas neste trabalho a versão original do PSO (EBERHART e KENNEDY, 1995) e sua variante que pondera um fator de inércia linearmente decrescente (SHI e EBERHART, 1999).

A fim de validar os resultados, esta pesquisa considera os seguintes critérios na comparação dos algoritmos:

- 1) Objetivo macro do problema estudado;
- 2) Gastos com energia elétrica;
- 3) Quantidade de carga alocada nos horários de pico;
- 4) Grau de viabilidade da solução, em relação às restrições consideradas no modelo matemático do problema.

1.4 Organização do Trabalho

Este trabalho está estruturado da seguinte forma:

- Capítulo 2 - concentra a revisão bibliográfica desta pesquisa, abordando os conceitos fundamentais em relação ao problema considerado, contemplando o detalhamento histórico sobre o Gerenciamento pelo Lado da Demanda, elucidação dos programas de *Demand Response*, analisando os dois tipos comumente implementados e os desafios

inerentes à gestão de energia elétrica residencial em *Smart Grids*. Além disso, é apresentada uma visão geral sobre a aplicação de meta-heurísticas na resolução do problema de *Demand Response*. Por fim, uma exposição acerca de trabalhos que modelam matematicamente o cenário de otimização de DR;

- Capítulo 3 – apresenta os resultados da análise bibliométrica desenvolvida neste trabalho acerca da área de pesquisa de *Demand Response*, os quais contemplam indicadores relevantes para a produção acadêmica neste campo;
- Capítulo 4 - detalha a formulação do problema de acordo com a modelagem considerada na pesquisa, elucidando a fundamentação matemática empregada no processo de otimização. Além disso, é apresentada uma visão geral acerca de métodos baseados em meta-heurísticas, concentrando amplo detalhamento acerca das variações do algoritmo PSO em detrimento de complexidade e escala de problemas;
- Capítulo 5 – descreve os materiais e métodos considerados neste trabalho, bem como a abordagem de otimização de DSM proposta. Em tempo, todos os mecanismos que compõem a proposta, além do detalhamento dos itens que compõem a base comparativa das discussões, são explanados;
- Capítulo 6 - são apresentados os resultados dos testes realizados, comparando a abordagem proposta com os demais métodos considerados no contexto deste trabalho;
- Capítulo 7 - por fim, são apresentadas as conclusões e diretivas para a continuidade da pesquisa no grupo de *Smart Grids* e Qualidade da Energia Elétrica.

Capítulo 2

REVISÃO BIBLIOGRÁFICA

Este capítulo busca ampliar o embasamento teórico discutido nesta dissertação. Nas seções subsequentes serão apresentados o referencial teórico relacionado à otimização da *Demand Response* baseada no preço da energia elétrica, a modelagem de tal problema e a aplicação de métodos de otimização, contemplando as meta-heurísticas.

2.1 Gerenciamento de Energia Elétrica pelo Lado da Demanda

Até a década de 70, as concessionárias de energia elétrica realizavam o planejamento de sua capacidade de distribuição de energia de acordo com o crescimento da demanda, uma vez que o consumo de energia elétrica apresentava um comportamento de grande previsibilidade (GELLINGS, 1985). Todavia, a partir dos anos 80 – devido a diversos fatores econômicos, políticos, sociais e tecnológicos (GELLINGS, 2017) – a demanda começou a se tornar cada vez menos previsível e, ao mesmo tempo, o setor energético enfrentou a escassez de fontes de energia de baixo custo. Conseqüentemente, estas variáveis contribuíram de maneira significativa para o aumento da complexidade em integrar metodologias de operação e planejamento tradicionais com o objetivo de influenciar deliberadamente a demanda de energia elétrica (GELLINGS, 1985).

Neste contexto, o Gerenciamento pelo Lado da Demanda foi concebido como o planejamento, implementação e monitoramento de atividades que visam influenciar

o uso da eletricidade de maneira que produza mudanças desejadas na curva de carga da concessionária de energia elétrica (GELLINGS, 2017). O termo DSM agrupa um conjunto de conceitos que recaem em uma mesma categoria, sendo considerado assim um hiperônimo, agregando diversas ações para o gerenciamento de carga, as quais inclui, por exemplo, a adoção de tarifas variáveis, medidas para uso racional de energia, substituição de combustíveis fósseis, eficiência energética e programas de *Demand Response*, conforme a Figura 1.

Figura 1: Atividades para o Gerenciamento pelo Lado da Demanda.



Fonte: Autor.

A correta implementação de atividades de DSM para a gestão de cargas mitiga os riscos que possam comprometer a eficiência e estabilidade do sistema, uma vez que possibilita o “alívio” da rede em horário de pico, aumento das fontes de geração distribuída que podem ser conectadas à rede de distribuição, além de outros relevantes benefícios inerentes aos agentes do mercado de energia (SIEBERT *et al.*, 2012).

Vale ressaltar que para uma atividade ser considerada pertencente à estrutura do DSM, esta deve ter como proponente a concessionária, uma vez que a mesma visa intervir deliberadamente na demanda de seus consumidores visando a alteração da curva de carga de um sistema elétrico. Logo, todas as ações tomadas pelo consumidor a fim de utilizar a energia de maneira eficiente, oriundas de sua percepção da necessidade da alteração em seu consumo de energia devido a questões financeiras e ambientais, por exemplo, não podem ser classificadas como DSM.

Deste modo, o DSM representa uma abordagem revolucionária para o planejamento em concessionárias de energia elétrica, uma vez que, essencialmente, ele amplia o escopo do planejamento para integrar as necessidades e desejos do consumidor com os objetivos da concessionária (GELLINGS e CHAMBERLIN, 1993), potencializando assim um equilíbrio necessário para garantir que o sistema de energia elétrica possa operar de maneira estável e confiável.

2.2 Demand Response

Demand Response pode ser definida como um conjunto de mecanismos que visam gerenciar os padrões de consumo de energia elétrica dos consumidores (demanda) em resposta às condições de geração, fornecimento, ambientais, econômicas, entre outras. Assim, a DR busca alterar a quantidade demandada de energia em um período específico de forma a aumentar a confiabilidade de uma rede, envolvendo diretamente os consumidores no processo de planejamento (ALBADI e EL-SAADANY, 2007; GELLINGS, 2017).

Segundo SILVA (2013), qualquer infraestrutura que possui períodos de congestionamentos e/ou subutilização estariam sujeitos à aplicação de programas de DR, na qual parte dos objetivos seria tornar o sistema mais eficiente, deslocando ou diminuindo o consumo em períodos críticos e aumentando a utilização da rede em períodos de baixo consumo.

De fato, estudos de implantação de programas de DR no setor de energia não começaram recentemente. Nos anos 80, conforme aborda GELLINGS (1985), já se discutiam os conceitos e tipos de gerenciamento da curva de carga pelo lado da demanda. Entretanto, devido ao avanço tecnológico do início do século XXI e à

redução nos custos de comunicação e automação, pesquisas acerca da aplicação de programas de DR ganharam maior atenção.

Impulsionada pelo conceito de *Smart Grids*, a aplicação de programas de *Demand Response* resulta em diversas vantagens para a concessionária, pois quando seus consumidores apresentam uma curva de carga mais plana, isso pode implicar em uma maior estabilidade no sistema de energia e aumento da capacidade de distribuição disponível.

Esta estrutura possibilita que as concessionárias e os consumidores se comuniquem em tempo real, enviando informações em sentido bidirecional. Desta forma, os sinais tarifários podem ser transmitidos aos consumidores com o intuito de que estes conheçam o custo da energia elétrica durante a operação do sistema elétrico. Os consumidores respondem aos sinais tarifários conforme a projeção de aumento ou redução do consumo ao nível desejado para a operação. Além disso, a energia residencial não consumida em períodos críticos pode ser muitas vezes comercializada para consumidores de grande porte, por um preço diferenciado. (SIANO, 2014).

Levando em consideração a capacidade dos consumidores em responder diante de uma ação do operador do sistema de acordo com a mudança no preço da tarifa ou com os pagamentos de incentivos, estima-se que o potencial de impacto da DR é tal que reduza o pico de demanda de 2019 em até 150 GW nos Estados Unidos (DOE, 2006; AGHAEI e ALIZADEH, 2013).

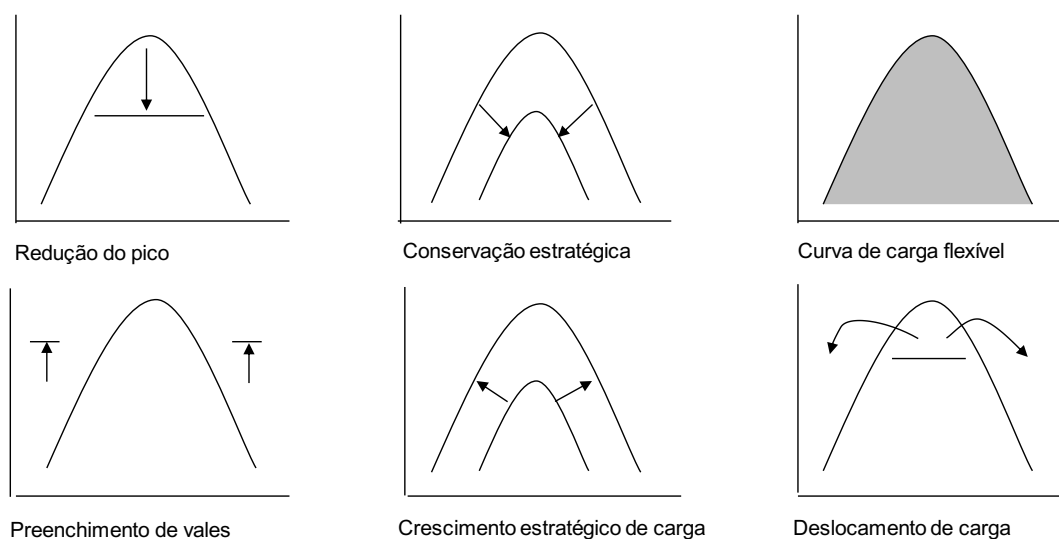
Segundo GELLINGS (1985), a DR inclui apenas as atividades que envolvem uma intervenção deliberada pelo operador do sistema para alterar a demanda do consumidor, mantendo assim a confiabilidade do sistema de energia de acordo com as diretrizes operacionais. Com base neste argumento, são definidas seis estratégias de gerenciamento de carga com base em programas de DR:

1. **Redução do pico** (do inglês, *peak clipping*) – trata-se do controle direto, pela concessionária, das cargas dos consumidores visando a redução da demanda de pico do sistema;
2. **Conservação estratégica** (do inglês, *strategic conservation*) – é o resultado da substituição de cargas por outras similares mais eficientes, tendo em vista uma redução geral da demanda em toda curva de carga;

3. **Curva de carga flexível** (do inglês, *flexible load shape*) – é um conceito relacionado à confiabilidade, onde o consumidor admite eventuais cortes ou redução da qualidade da energia fornecida, em troca de benefícios financeiros
4. **Preenchimento de vales** (do inglês, *valley filling*) – é a forma direta de melhorar o fator de carga e conseqüente redução do custo de energia, geralmente realizada pelo armazenamento de energia fora do horário de pico;
5. **Crescimento estratégico de carga** (do inglês, *strategic load growth*) – é o crescimento das vendas de energia elétrica estimuladas pela concessionária, além do preenchimento de vales descrito anteriormente. Pode ocorrer por meio de incentivos, tais como a substituição de óleo combustível por eletricidade em caldeiras industriais, redução de tarifa e incentivo na utilização de veículos elétricos;
6. **Deslocamento de carga** (do inglês, *load shifting*) – envolve o deslocamento da carga do horário de pico, acompanhada ou não de armazenamento de energia.

As definições acerca destas estratégias podem ser observadas na Figura 2.

Figura 2: Estratégias de Gerenciamento de Carga.



Fonte: Adaptado de GELLINGS (1985).

Segundo FARIA e VALE (2011), além do aspecto operacional relevante que o DSM constitui para o operador do sistema, este também viabiliza uma série de novos negócios no mercado de energia. Neste sentido, o consumidor participa ativamente de forma a influenciar na geração de energia elétrica e nas tarifas cobradas pela concessionária. Assim, de consumidores a pequenos fornecedores de energia, os participantes do sistema poderiam comercializar o excedente produzido com os operadores do sistema, tendo algum benefício financeiro.

2.3 Classificação dos Programas de *Demand Response*

Apoiada nas novas tecnologias destinadas à operação da rede, a informação sobre o valor da tarifa de energia elétrica torna-se cada vez mais rápida, estabelecendo novos desafios para o DSM. Conforme GELLINGS e CHAMBERLIN (1993), um programa de *Demand Response* pode ser basicamente de dois tipos: DR com Base em Incentivos (IBDR, do inglês *Incentive-Based Demand Response*) e DR com Base em Preços (PBDR, do inglês *Price-Based Demand Response*). Tais classificações podem ser melhor compreendidas por meio da Figura 3.

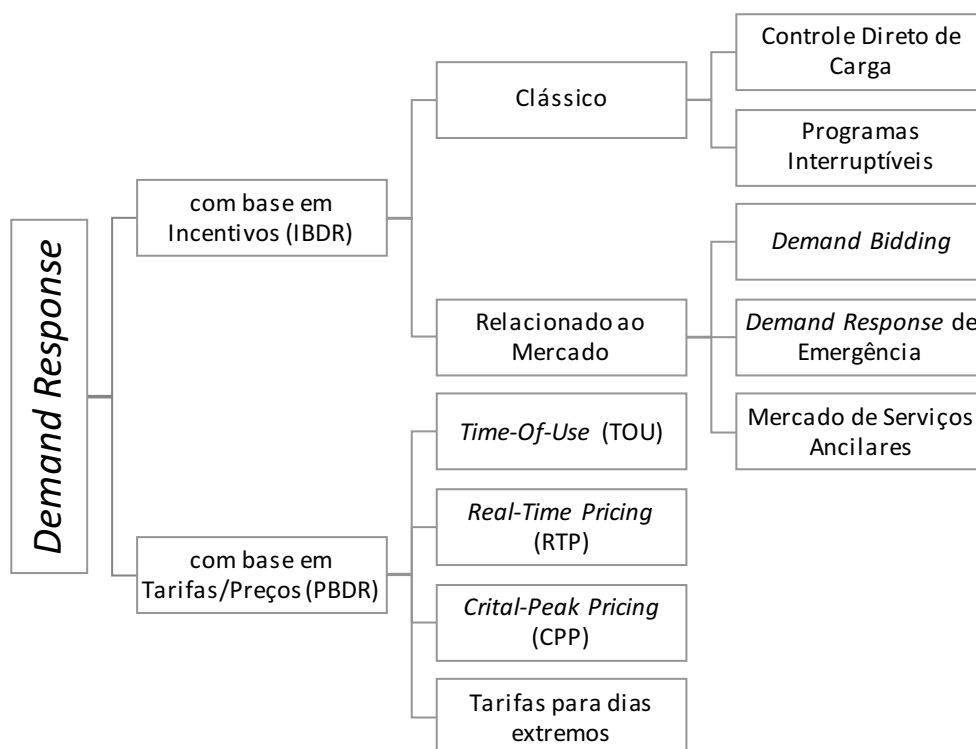
Nas seções que seguem, ambos os programas serão brevemente descritos, porém cabe comentar que o presente trabalho tratará de programas de DR baseados em Tarifas/Preços (PBDR).

2.3.1 Programas Baseados em Incentivos

Constitui-se em acordos contratuais estabelecidos pelo operador da rede junto aos consumidores para que estes contribuam com reduções de consumo necessárias em momentos críticos. Assim, contando com a adesão voluntária dos consumidores, o despacho de energia neste tipo de programa geralmente ocorre em horários previamente definidos ou quando a estabilidade do sistema está comprometida.

Conforme visto na Figura 3, ALBADI e EL-SAADANY (2007) subdividem os programas de IBDR em:

Figura 3: Estruturas de Programas de Resposta à Demanda.



Fonte: Adaptado de ALBADI e EL-SAADANY (2007).

- **Clássico** – os consumidores participantes recebem incentivos financeiros, usualmente na forma de créditos de energia ou descontos na fatura por sua participação nos programas. As principais ações no modelo clássico são:
 - (1) **Controle direto de carga** – a concessionária possui a permissão de remotamente desligar cargas dos consumidores, tais como condicionadores de ar e aquecedores de água do tipo caldeira;
 - (2) **Programas interrompíveis** – os consumidores são solicitados a reduzirem seu consumo a um nível pré-determinado, em situações de necessidade para a rede, correndo o risco de sofrerem penalidades caso não o façam;
- **Relacionada ao mercado** – os participantes são geralmente compensados diretamente com dinheiro por seu desempenho, dependendo da quantidade e do momento da redução exercida durante períodos críticos para o sistema, bem como:
 - (1) **demand bidding (ou leilões de redução de demanda)** – funcionam de forma similar a uma bolsa de valores de redução de energia;

- (2) **demand response de emergência** – remunera consumidores por reduções de energia medidas quando o sistema está em condições de emergência;
- (3) **mercado de serviços ancilares** – operam de modo similar à **demand bidding**, porém com foco nos serviços ancilares. Assim como em serviços ancilares tradicionais, a remuneração pode ser fornecida separadamente para capacidade de reserva e para provisão de energia.

Conforme já citado, programas de IBDR não serão abordados neste trabalho. Modelagens matemáticas destes podem ser encontradas em UTURBEY (2002) e FARIA (2011).

2.3.2 Programas Baseados em Tarifas/Preços

O cálculo do valor da energia, em geral, leva em consideração parâmetros inerentes à sua produção e a situação corrente da demanda pela energia elétrica, possuindo este último um grande impacto no cálculo, uma vez que um elevado consumo concentrado em um mesmo intervalo de tempo pode sobrecarregar todo o sistema de geração e transmissão de energia, colocando em risco a confiabilidade do sistema (DOE, 2006). Sendo assim, o valor final da energia pode variar ao longo do tempo. No entanto, esta variação pode ter um padrão com valores bem-definidos para cada instante de tempo e/ou extraídos a partir da observação do padrão de consumo dos consumidores ou então pode variar de forma volátil (HAIDER, SEE e ELMENREICH, 2016). Logo, é possível implementar tarifas mais elevadas para momentos em que o sistema elétrico está exposto a picos de consumo, suavizando deste modo a curva de carga da rede.

Diante deste contexto, os programas de DR aderem, em larga escala, aos incentivos tarifários a fim de modificar o padrão de demanda dos consumidores.

De acordo com ALBADI e EL-SAADANY (2007), existem diversas formas de implementar programas de PBDR. Todavia, segundo os autores, estes programas comumente fazem uso de um dos três modos de tarifação:

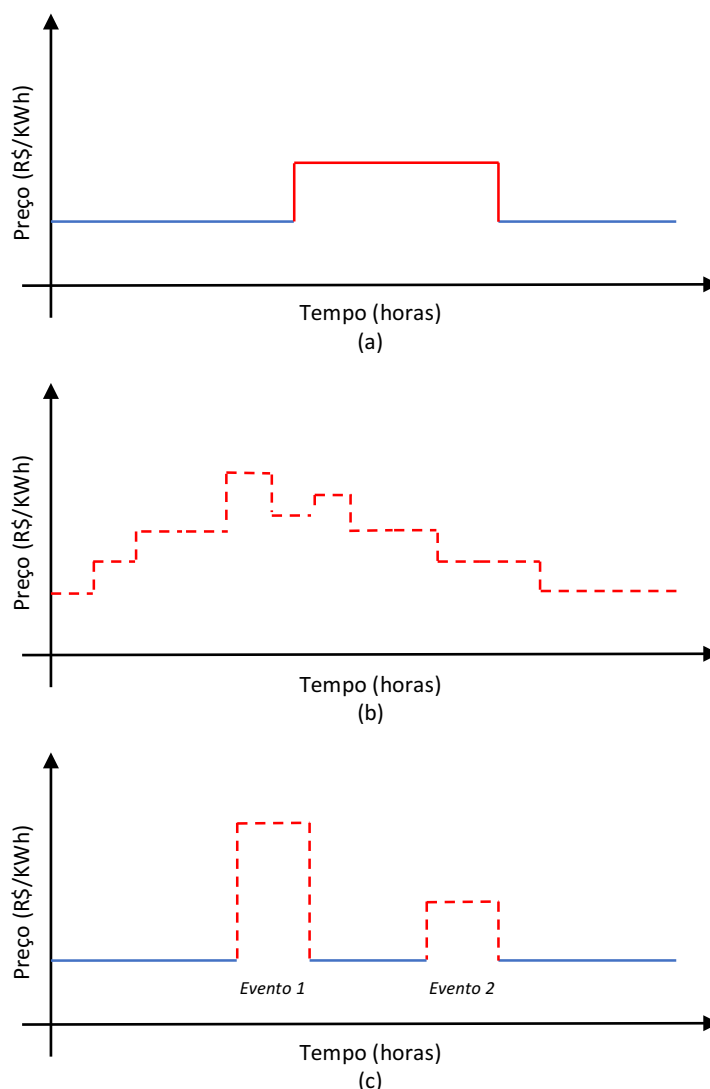
- **Time-of-Use (TOU)** – neste modelo de tarifação, a concessionária estabelece preços que variam de acordo com períodos de tempo pré-

definidos, podendo contemplar horas do dia, dias da semana ou estações do ano. Segundo ALBADI e EL-SAADANY (2007), o objetivo do TOU é estabelecer sinais tarifários que precifique a energia elétrica de acordo com o nível de consumo em relação à capacidade do sistema. Normalmente, os preços estabelecidos neste modelo sofrem poucas alterações durante o ano, o que contribui de maneira significativa para a previsibilidade de custos ao consumidor. Entretanto, com o passar do tempo, tal comportamento pode gerar gargalos na precificação, uma vez que determinada tarifa corrente pode não refletir exatamente as mesmas condições que foram consideradas no momento de seu cálculo;

- **Real-Time Pricing (RTP)** – na precificação em tempo real, os consumidores estão expostos a tarifas que, em determinado período, refletem as condições de oferta e demanda do sistema (ALBADI e EL-SAADANY, 2007). Logo, este programa representa uma sinalização econômica flexível e coesa para o mercado, mitigando algumas das limitações da tarifação TOU. Em contrapartida, dado que os consumidores tomam ciência da tarifa cobrada com um dia ou uma hora de antecedência (DOE, 2006), este modelo pode gerar confusão para o consumidor no gerenciamento de seu consumo energético diante das tarifas disponíveis;
- **Critical-Peak Pricing (CPP)** – este modelo representa uma alternativa híbrida de precificação a partir dos programas TOU e RTP. Conforme ALBADI e EL-SAADANY (2007), o CPP, a partir da estrutura tarifária TOU, adota tarifas eventuais para situações em que o sistema apresente condições críticas de pico, as quais podem comprometer de modo significativo o funcionamento do sistema. Essas tarifas, dada a característica emergencial, são notificadas em curtíssimo prazo pela concessionária. Em tempo, vale ressaltar que nesse tipo de programa é estabelecida uma limitação de 50 a 100 períodos críticos por ano, a fim de contemplar eventuais e necessários ajustes na estrutura tarifária.

A Figura 4 apresenta o comportamento tarifário de cada um destes programas, ou seja, exhibe a flutuação do preço de energia cobrado dentro de um horizonte de tempo considerado.

Figura 4: Representação da variação de preço da energia ao longo do dia nos programas de tarifação: (a) *Time-of-Use*, (b) *Real-Time Pricing* e (c) *Critical-Peak Pricing*.



Fonte: Adaptado de HAIDER, SEE e ELMENREICH (2016).

Portanto, a implementação destes programas viabiliza um cenário “ganha-ganha” no qual os consumidores podem diminuir seus custos com energia elétrica e as concessionárias de energia não precisam investir em infraestrutura para aumentar sua capacidade de fornecimento de energia.

Todavia, a aderência aos programas de DR – a fim de extrair os potenciais benefícios que estes podem oferecer – não é uma tarefa trivial, seja para consumidores industriais, comerciais ou residenciais. Para os consumidores industriais, além da estrutura física, a escolha do modelo de tarifação a ser adotado

reflete um imenso desafio, pois deve considerar estabelecer sinais tarifários que permitam garantir a segurança do sistema por meio de valores que sejam factíveis, de modo que este vislumbre vantagens reais em alterar seu padrão de consumo frente às tarifas cobradas. Já para os consumidores residenciais, ter acesso à tarifa variável ao longo do tempo não garante a redução da conta de energia elétrica, uma vez que para tal objetivo ser atingido é necessário um agendamento complexo da carga energética, que considere, além da tarifa em cada instante de tempo, as características de funcionamento das cargas contempladas, bem como o contexto cotidiano das pessoas presentes na residência.

2.4 Otimização de *Demand Response*

GELLINGS (2017) descreve os principais conceitos do DSM, seus objetivos intrínsecos e a evolução desde sua proposição. O autor ainda apresenta um resumo sobre os programas de DR e o impacto que estes geram na economia Norte Americana. Por fim, o autor conclui que tais mecanismos representam uma maneira efetiva de gerenciar a demanda por serviços de energia elétrica de acordo com os recursos disponíveis, sendo um meio efetivo de ampliar a eficácia e a funcionalidade dos sistemas elétricos. PALENSKY e DIETRICH (2011) ressaltam que, embora exista muita experiência na otimização da geração e distribuição de energia, é o lado da demanda que recebe cada vez mais atenção pela pesquisa e pela indústria.

Neste sentido, HAIDER, SEE e ELMENREICH (2016) apresentam uma visão geral da literatura sobre programas de DR. Assim, são expostas as principais técnicas de agendamento de carga e as últimas tecnologias de informação e comunicação que suportam aplicações de *Demand Response* no setor residencial. Os autores mostram que a maioria das estratégias de programas de DR implementadas atualmente oferece a todos os consumidores, de diferentes perfis de consumo, um mesmo preço de energia para um determinado período de tempo. O principal problema desta estratégia é a externalidade negativa entre os consumidores, o que significa que um aumento na demanda de determinado consumidor cria um efeito de externalidade negativa para a taxa de preços de outros consumidores. Ainda, segundo os autores, uma recomendação para mitigar esta questão é a implementação de um esquema de

preços adaptativo baseado no nível de consumo. Por fim, o estudo conclui que a economia, em termos de custo da energia, pode ser alcançada pela cooperação entre concessionária e consumidores, ao mesmo tempo que são equilibrados os benefícios entre eles. Este equilíbrio é um cenário desafiador para a otimização da DR, o qual será considerado dentro dos objetivos desta dissertação, conforme será detalhado na Seção 5.2.

Uma revisão abrangente de vários tipos programas de DR e métodos de otimização que foram propostos na literatura, os quais envolvem diretamente a participação de consumidores, são apresentados em VARDAKAS e ZORBA (2015). Neste trabalho, os autores classificam os modelos de otimização de programas de DR com base em distintos objetivos, contemplando as restrições inerentes do sistema e a complexidade computacional das soluções disponíveis. Estas categorias incluem: a) minimização do custo da eletricidade, b) maximização do bem-estar social, c) minimização do consumo agregado de energia, d) minimização do custo da eletricidade e do consumo agregado de energia, e e) tanto a maximização do bem-estar social como a minimização de consumo de energia agregado.

BATCHU e PINDORIYA (2015) destacam que o setor residencial desempenha um papel fundamental no quadro das *Smart Grids*, devido a seu desproporcional consumo de energia em momentos de pico e ao potencial de integração massiva da geração de energia renovável local e distribuída em conjunto com dispositivos de armazenamento de energia elétrica. No trabalho em questão, os autores apresentam uma visão geral sobre a DR residencial e seu modelo de otimização considerando um conjunto de residências. Além disso, uma descrição de trabalhos que abordam os métodos de otimização utilizados atualmente - como Heurísticas, Algoritmos Genéticos (GA, do inglês, *Genetic Algorithm*), Enxame de Partículas (PSO, do inglês *Particle Swarm Optimization*), Programação Linear Inteira Mista (MILP, do inglês *Mixed-Integer Linear Programming*) (GOLDBARG, GOLDBARG e LUNA, 2016) - são descritos no trabalho, os quais visam, entre outros objetivos, otimizar o consumo de eletrodomésticos considerando suas especificações, o custo da energia e o conforto associado à utilização destes. Corroborando com o trabalho de HAIDER, SEE e ELMENREICH (2016), os autores concluem que as técnicas de otimização da DR têm como um dos principais desafios lidar com os múltiplos objetivos de um sistema elétrico. Assim, tais métodos devem ser explorados em trabalhos futuros de modo a

avaliar seus méritos e deficiências relativos à adequação, complexidade computacional e desafios de integração em cenários reais de grande porte.

Um exemplo da premissa supracitada está presente em ZHOU *et al.* (2014b), onde é proposto um método para a otimização do gerenciamento de energia residencial em uma *Smart Grid*. Os autores desenvolvem um sistema capaz de gerar um agendamento de cargas residenciais, envolvendo, por meio de suas informações, concessionária e consumidores. O objetivo é minimizar o custo da energia consumida diariamente, considerando as restrições relacionadas à limitação do uso de energia, tarifação do tipo TOU, características das cargas e hábitos dos moradores. Tal método desenvolvido, baseado em programação linear inteira e no algoritmo *branch-and-bound*, mostrou ser capaz de reduzir em quase 29% o valor da conta de energia ao mesmo tempo que diminui em 56,5% o pico de consumo. Todavia, conforme concluem os autores, os resultados foram obtidos por meio de testes em pequena escala, ou seja, contemplando a otimização de um cenário residencial que possui poucas cargas eletrodomésticas.

Por fim, BARBATO e CAPONE (2014) apresentam um levantamento contendo os estudos mais relevantes sobre métodos de otimização para DSM de consumidores residenciais. Especificamente, os autores revisam a literatura relacionada de acordo com três eixos que definem características contrastantes dos modelos propostos: DSM para consumidores individuais *versus* DSM para consumidores cooperativos; DSM determinístico *versus* DSM estocástico; e DSM diurno *versus* DSM em tempo real. Com base nesse estudo, é possível obter um panorama geral das principais características de diferentes abordagens e técnicas relacionadas ao tema. Trabalhos semelhantes são encontrados em DENG *et al.*, 2015 e ESTHER e KUMAR, 2016.

2.5 Gestão de Cargas Residenciais com Meta-heurísticas

Como previamente apresentado, métodos de otimização têm sido propostos por pesquisadores do mundo todo, visando aumentar a eficiência energética e reduzir gastos com o consumo de energia de consumidores residenciais, tirando proveito de programas de DR. Neste sentido, motivados pela complexidade do problema de DR,

alguns autores têm realizado importantes levantamentos acerca da viabilidade de aplicação das meta-heurísticas nesta área de pesquisa.

HA *et al.* (2009) propõem um sistema de automação que gerencia a carga residencial. Como a complexidade desse problema é NP-Difícil, os autores desenvolveram um algoritmo apoiado em duas meta-heurísticas (*Tabu Search* e *Simulated Annealing*) para solucioná-lo. Estabelecendo diferentes métricas e limitações técnicas, como limites computacionais, os autores mostram que a adoção de ambas as meta-heurísticas se mostram factíveis no gerenciamento de carga residencial, gerando agendamentos de cargas otimizados que consideram as restrições de custo e conforto de modo eficiente, inclusive salientando que a solução obtida por estas abordagens é comparável à melhor solução encontrada pelo método MILP para este problema, considerando um tempo de computação limitado igual a 3600 CPUs (tempo de computação em segundos).

VALLE *et al.* (2008) apresentam um estudo consistente sobre a utilização do algoritmo PSO em diferentes aplicações no sistema elétrico, incluindo a gestão de carga em *Smart Grids*. Para cada aplicação, o estudo apresenta as nuances para a eficiente aplicação do PSO, como: a variação do algoritmo adotada; formulação dos indivíduos (representação da solução); e as funções de *fitness* mais eficientes. ZHOU *et al.* (2014b) e ABEDIN *et al.* (2015) apresentam estudos similares, porém com foco em aplicações de DSM.

LOGENTHIRAN, SRINIVASAN e PHYU (2015) propõem a aplicação do algoritmo de Otimização por Enxame de Partículas Binária (BPSO, do inglês *Binary Particle Swarm Optimization*) para a resolução do gerenciamento de cargas em uma *Smart Grid*, otimizando as curvas de carga de consumidores residenciais, comerciais e industriais. A proposta leva em consideração as preferências individuais dos usuários para o funcionamento das cargas, estabelecendo prioridades e intervalos de tempo preferidos para o agendamento.

SIEBERT *et al.* (2012) apresentam uma proposta de aplicação do GA para a proposição de agendamento de consumo de cargas residenciais. Considerando um conjunto pequeno de cargas e adotando tarifação variável do preço da energia (do tipo TOU), a proposta possui caráter multiobjetivo, visando diminuir o custo da energia consumida ao mesmo tempo que suaviza a curva de demanda em um horizonte de 24 horas.

Visando ampliar o trabalho anterior, TEIXEIRA e FERREIRA (2014) comparam a aplicação dos algoritmos GA e PSO no problema de agendamento de carga de uma residência, contemplando um pequeno número de eletrodomésticos. Neste trabalho, os autores levam em consideração a geração própria de energia (solar e eólica), além da presença de um veículo elétrico.

REMANI, JASMIN e AHAMED (2015) apresentam um algoritmo baseado no BPSO para resolver o problema de agendamento de carga com diferentes tipos de cargas e restrições operacionais. A proposta também leva em consideração um limite de Demanda Máxima imposta pela concessionária, visando garantir a estabilidade do sistema.

Por fim, ZAFAR *et al.* (2017) avaliam o desempenho de três técnicas de otimização baseados em meta-heurísticas: *Harmony Search Algorithm* (HSA), *Bacterial Foraging Optimization* (BFO) e *Enhanced Differential Evolution* (EDE). Desta forma, é assumido um modelo que visa minimizar o custo da energia, o consumo de energia, a redução do PAR e maximizar o conforto do usuário. Os autores levam em conta cargas pertencentes a três categorias distintas, classificadas de acordo com seus respectivos padrões de consumo. Ainda, é assumido um esquema de preços do tipo RTP para o cálculo da tarifa de energia.

2.6 Modelagem do Problema de Otimização de DR

A modelagem matemática de um problema de otimização é de fundamental importância no processo de resolução deste, pois esta define as regras que regem o universo do problema em sincronia com os objetivos intrínsecos a este, além de delimitar o arcabouço de técnicas factíveis de serem aplicadas no processo de otimização. No contexto das DSM, diversos modelos têm sido discutidos na literatura, os quais possuem particularidades em relação ao setor elétrico (mercado) em que está inserido, ao funcionamento de diferentes tipos de cargas, presença de baterias de armazenamento ou veículos elétricos, produção própria de energia, premissas de usabilidade e conforto dos residentes, e outras. Ademais, uma ampla gama de metodologias de otimização é investigada a fim de avaliar os potenciais e limitações destes modelos em diferentes cenários.

MOHSENIAN-RAD *et al.* (2010) propõem um modelo matemático que reflete a interação entre os consumidores de uma *Smart Grid*, de modo a obter vantagem da infraestrutura de comunicação bidirecional. Para resolução do modelo proposto, os autores se apoiaram na teoria dos jogos e formularam um jogo do cronograma do consumo de energia, onde os jogadores são os consumidores e suas estratégias são os agendamentos de suas cargas em detrimento de restrições de carga e do estilo de vida destes. O objetivo do jogo é reduzir o consumo de energia, o custo da energia e a diferença entre o consumo do horário de pico e dos demais horários.

Considerando esta modelagem, LEE e LEE (2011) propõem um algoritmo de agendamento de carga que controla o tempo de operação e o consumo de energia de cada carga, adaptando-se à tarifação TOU adotada pela concessionária, que considera suas características de operação e consumo de energia, com o objetivo único de minimizar o valor final da conta de energia. Os autores expandem estudos anteriores ao descrever modelos matemáticos de quatro classes de funcionamento de cargas, além de considerar cargas cujo consumo de energia pode ser controlado de forma contínua e elástica, ou não. Os resultados mostram que a proposta pode reduzir significativamente o valor final da conta, agendando efetivamente o tempo de operação e o consumo de energia de cada carga, considerando suas características de operação e restrições de consumo.

De modo similar, CHO (2013) desenvolve um algoritmo para o gerenciamento de carga residencial objetivando minimizar o custo total de energia (frente a uma tarifação de energia variável) e suavizar a curva de carga para um horizonte de planejamento diário. Vale ressaltar que o autor leva em consideração dois tipos diferentes de famílias e três categorias diferentes de cargas. Após os testes, o algoritmo desenvolvido mostrou-se eficiente em reduzir o custo da energia, mas não cumpre o objetivo de diminuir o pico de consumo em todas as ocasiões.

CHAVALI, YANG e NEHORAI (2014) desenvolveram um algoritmo iterativo para o agendamento de cargas que encontra uma hora de início ideal e modo de operação eficiente para as cargas em resposta à variação de preços da energia. Tal abordagem, dada que a resolução da otimização se denota NP-Difícil, é baseada em estratégia de programação gulosa. Considerando um conjunto de consumidores, o agendamento ótimo de cada carga é calculado de forma isolada. Deste modo, é possível proporcionar uma maior privacidade nas informações transmitidas para a

concessionária. As simulações mostram que o método de otimização diminui o custo para os consumidores e viabiliza cortes de pico de consumo no sistema elétrico.

Em HUANG, TIAN e WANG (2015), os autores propõem um modelo matemático para o escalonamento da operação dos equipamentos de uma residência no contexto de uma SG, o qual será adotado nesta dissertação – melhor detalhado na Seção 4.1. Em linhas gerais, o modelo define três tipos distintos de cargas, considera uma tarifa TOU, produção de energia fotovoltaica e a presença de um veículo elétrico que está sempre conectado à residência e possui dispositivo de armazenamento de energia, podendo ser carregado e descarregado dentro do horizonte de planejamento. Para a resolução do modelo, os autores se apoiaram no algoritmo PSO, o qual contempla uma hibridização no processo de exploração do espaço de busca, sendo a versão canônica responsável pela atualização das dimensões reais (carga e descarga da bateria) e a versão binária responsável pela exploração das dimensões deste tipo (planejamento de operação das cargas). Assumindo um amplo conjunto de restrições, o objetivo é reduzir o custo com o consumo de energia elétrica, mantendo as premissas de estilo de vida e conforto dos indivíduos frente às características das cargas, variações tarifárias, utilização sustentável da bateria e da energia gerada pelos painéis fotovoltaicos. O estudo mostra que o algoritmo proposto é eficiente na redução da energia consumida. Todavia, ainda que promissores, os resultados contemplam um cenário simulado de pequeno porte, com apenas 3 cargas.

Visando reduzir o consumo de energia e maximizar o conforto dos residentes, bem como reduzir a razão entre demanda máxima e média, ou seja, o PAR, JAVAID *et al.* (2017) aplicaram os algoritmos genético, BPSO, BFO e *Wind-Driven Optimization* (WDO), além da proposta de um algoritmo híbrido baseado em GA e WDO. Os autores buscaram otimizar o planejamento da operação de equipamentos residenciais frente a uma tarifa de tempo real para a energia. O GA se mostrou a melhor opção para gerenciamento de consumo de energia e redução de custos, enquanto o BPSO e o BFA tiveram melhor desempenho nos cenários que contavam com populações menores.

SPAVIERI, FERNANDES e VALE (2017) aplicam e avaliam o desempenho do Algoritmo de Busca Gravitacional para a otimização de demanda com foco principal na determinação de estratégias de consumo de energia elétrica que venham a minimizar os custos para consumidores residenciais. Considerando um conjunto de 3

residências e uma tarifação do tipo RTP para o valor da energia elétrica, os autores afirmam que o resultado obtido se mostrou devidamente coerente com a variação dos valores da tarifa paga pelo consumo de energia elétrica e com a redução dos picos de consumo pela minimização do PAR.

Com base nestes trabalhos, abre-se a possibilidade de investigação de métodos da classe de meta-heurísticas no processo de otimização do planejamento de operação de cargas residenciais. Logo, considerando o contexto das SGs, o principal objetivo desta dissertação é propor uma nova abordagem computacional para a resolução do problema de DSM, assumindo um modelo matemático cuja premissa é minimizar a conta de energia elétrica considerando a variação da tarifa cobrada pela concessionária, a produção e armazenamento sustentável de energia, bem como mensurar sua viabilidade de aplicação em cenários reais, levando em conta todas as restrições inerentes a este contexto.

Capítulo 3

ANÁLISE BIBLIOMÉTRICA DA ÁREA DE *DEMAND RESPONSE*

A fim de explorar de maneira ampla o problema investigado neste trabalho e compreender os caminhos que as produções científicas inerentes a estes vêm tomando nos últimos anos, foi realizada a análise bibliométrica da área de *Demand Response*. Cabe ressaltar que não se encontra na literatura, até o presente momento, um estudo similar a este que compreende um levantamento a respeito de programas de DR baseados em Tarifas/Preços, reforçando a importância desta etapa da pesquisa.

Para o levantamento bibliográfico foi utilizada a base de dados de produções acadêmicas *Scopus* que, segundo a Elsevier é a maior base de resumos e citações de literatura científica revisada por pares.

As buscas na base *Scopus* foram realizadas no dia 02 de janeiro de 2017, onde contemplou-se um período compreendido entre os anos de 2006 a 2016. Em tempo, cabe destacar que foram consideradas duas tipologias documentais: artigos técnico-científicos e *reviews* (revisões bibliográficas).

Para a recuperação das publicações na base de dados, além dos filtros previamente citados, de acordo com a proposta de mapeamento deste trabalho, foram utilizados os termos “*demand response*”, “*time of use*”, “*tou*”, “*real-time pricing*”, “*rtp*”, “*critical peak pricing*” e “*cpp*” como descritores ocorridos no título, resumo e palavras-chaves. Com estes parâmetros, a busca foi realizada por meio da interface de pesquisa da *Scopus*, resultando em 504 publicações. Os dados coletados tiveram dois tipos de tratamento:

1. Foram exportados para um arquivo do tipo texto, o qual serviu de base para o conjunto de dados. Posteriormente, as publicações foram categorizadas como pertencentes a uma (ou mais de uma) das três abordagens de programas de *Demand Response* baseados em Tarifas/Preços. Por exemplo, ao realizar a pesquisa com os descritores “*demand response*”, “*time of use*” e “*tou*”, as publicações resultantes são categorizadas no conjunto de dados como pertencentes ao programa “*Time of use (TOU)*”. É importante ressaltar que uma mesma publicação pode estar categorizada em mais de um programa, o que faz todo o sentido, dado que, por exemplo, “*tou*” e “*rtp*” aparecem como pertencentes ao conjunto de palavras-chave definidas pelo autor para a publicação ou ambas estão presentes no resumo do trabalho. Este tratamento viabiliza a análise do conteúdo da literatura relacionada a estes programas de DR;
2. Um segundo conjunto de dados no formato de arquivo “.bib” foi concebido a partir dos resultados de pesquisa global, ou seja, por meio da combinação de todos os descritores supramencionados, os quais serviram de entrada para a análise bibliométrica realizada, que será detalhada posteriormente.

Para a análise dos dados foi utilizado o software R (R CORE TEAM, 2016), que engloba uma linguagem e ambiente para computação estatística. Dessa forma, o R fornece uma ampla variedade de recursos para computação de cálculos estatísticos e de visualização de dados. Além dos recursos nativos, o software R permite a extensão de suas funcionalidades por meio da instalação de pacotes – ou bibliotecas – mantidos pela comunidade. No contexto deste trabalho, além de usar as funções nativas para geração de gráficos, também foi utilizado o pacote *ggplot2* (WICKHAM, 2009), o qual consiste em uma biblioteca também capaz de gerar gráficos, ampliando as possibilidades de visualização de dados do R com base nos princípios da gramática de gráficos proposta por WILKINSON (2005).

Por fim, também foi utilizado o pacote *Bibliometrix*, proposto por ARIA e CUCCURULLO (2016), que fornece rotinas para importar dados bibliográficos e realizar análises bibliométricas por meio da inferência de indicadores de co-citações,

acoplamentos, análise de colaboração científica e de co-palavras, os quais serão abordados na sequência.

3.1 Indicadores Gerais

A partir das definições previamente citadas, esse trabalho obteve uma coletânea de publicações acerca da área de DR e de seus três principais programas baseados em tarifas/preços. O levantamento bibliográfico realizado contempla 504 artigos científicos recuperados de 136 fontes distintas, com uma média de 18,31 citações por artigo, considerando 1222 autores, os quais definiram um total de 1276 palavras-chave. Os dados analisados podem ser visualizados, de modo sumarizado, na Tabela 1. Portanto, essa tabela foi constituída por indicadores gerais a respeito da produção bibliográfica disponível no recorte produzido, os quais serão detalhados no decorrer desta dissertação.

Tabela 1: Indicadores gerais obtidos em relação ao conjunto de dados.


Período	2006 – 2016
Artigos	504
Fontes (Periódicos)	136
Palavras-chaves dos Autores	1276
Palavras-chaves do Periódico	2993
Média de Citações por Artigo	18,31
Autores	1222
Aparecimento dos Autores	1688
Artigos com único Autor	22
Artigos com múltiplos Autores	1200
Artigos por Autor	0,412
Autores por Artigo	2,42
Coautores por Artigo	3,35
Índice de Colaboração	2,53

Fonte: Autor.

3.2 Evolução Histórica de Publicações

Esse primeiro indicador analisado corresponde à evolução histórica das publicações, o qual fornece uma visão geral sobre as publicações de artigos na área de programas de DR baseados em Tarifas/Preços. Fica claro, conforme a Figura 5, que a área de pesquisa em questão vem crescendo de maneira consistente na última década, apresentando uma taxa de crescimento anual em torno de 30% no período analisado.

Figura 5: Evolução do número de publicações por ano.



Fonte: Autor.

Observa-se que a partir de 2009, o número de publicações vem subindo consideravelmente ano após ano, atingindo um total de 125 artigos em 2016, sendo este o máximo registrado na série histórica. Tal fenômeno pode ser explicado pelo salto tecnológico corrente, o qual vem viabilizando a implementação das *Smart Grids*, conforme citado anteriormente.

3.3 Publicações por Tipo de Programa de DR Baseado em Tarifas/Preço

Uma das partes substanciais desta análise consiste em entender o comportamento do cenário acadêmico que tange as publicações de acordo com cada um dos três principais programas de *Demand Response* baseados em Tarifas/Preços, sendo estes, conforme citado: *Time-of-use (TOU)*, *Real-Time Pricing (RTP)* e *Critical-Peak Pricing (CPP)*. Neste contexto, por meio do levantamento realizado, puderam ser obtidos os dados da Tabela 2.

Tabela 2: Publicações por programas de DR baseados em tarifas/preços.

Programas	Artigos
<i>Real-time Pricing (RTP)</i>	355
<i>Time-of-use Pricing (TOU)</i>	151
<i>Critical-peak Pricing (CPP)</i>	51

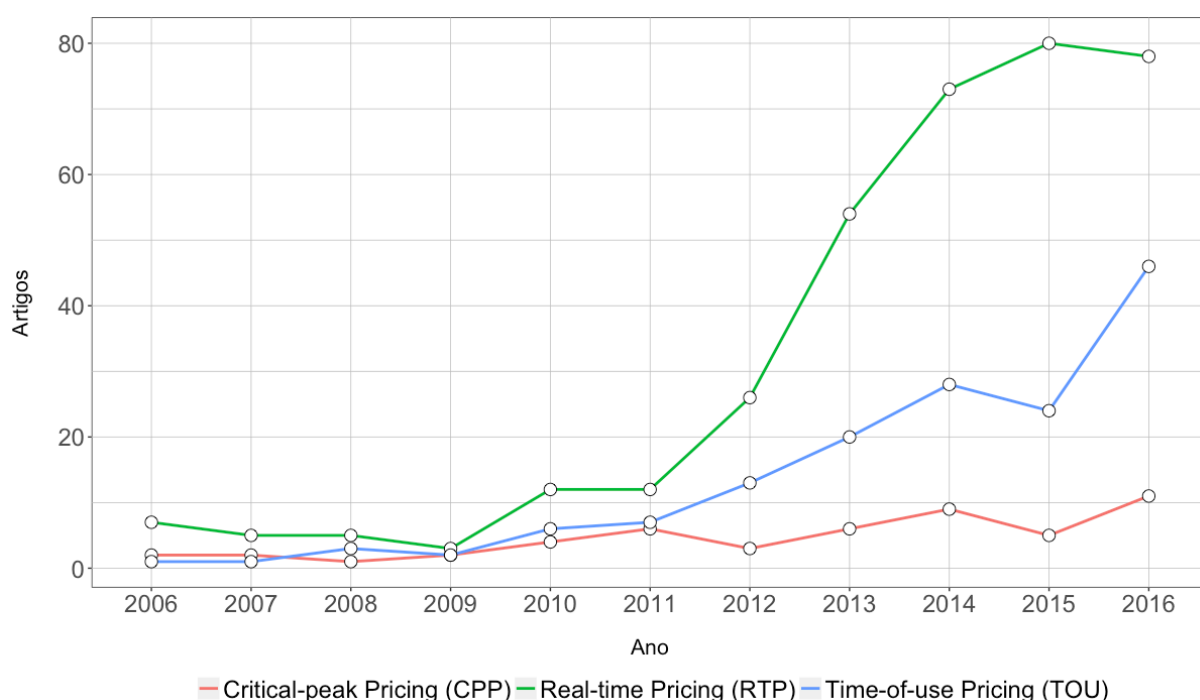
Fonte: Autor.

Nota-se, portanto, que as publicações nesta área têm se concentrado em programas do tipo RTP, que totaliza 63,7% dos registros obtidos no levantamento. A fim de compreender de maneira mais específica este resultado, analisar o comportamento histórico (série temporal) do volume de publicações na área de acordo com estas três categorias de programas baseados em tarifas/preços viabiliza o entendimento em relação à evolução da área, conforme pode ser observado na Figura 6.

É interessante notar que, até o ano de 2009, as publicações em cada programa baseado em tarifas/preços possuíam similaridade em termos de produtividade, indicando um interesse acadêmico igualitário para cada programa. Porém, a partir de 2010 fica evidente uma clara discrepância na publicação de trabalhos sobre RTP em relação aos demais. É interessante notar que, trabalhos sobre RTP atingiram o maior número de publicações em 2015, apresentando uma pequena queda em 2016. Já os trabalhos sobre TOU, ainda que em menor número de publicações em relação aos de

RTP na série histórica, apresentaram um crescimento significativo em 2016 quando comparado ao ano anterior. Por fim, fica evidente a estagnação em publicações classificadas como CPP no recorte analisado, mesmo obtendo a máxima histórica em 2016, superando o ano de 2014. O detalhamento deste gráfico pode ser observado na Tabela 3.

Figura 6: Evolução histórica de publicações sobre cada programa de DR baseado em tarifas/preços.



Fonte: Autor.

Tabela 3: Número de publicações sobre os programas de DR baseados em tarifas/preços por ano.

Ano	Critical-peak Pricing (CPP)	Real-time Pricing (RTP)	Time-of-use Pricing (TOU)
2006	2	7	1
2007	2	5	1
2008	1	5	3
2009	2	3	2
2010	4	12	6
2011	6	12	7


2012	3	26	13
2013	6	54	20
2014	9	73	28
2015	5	80	24
2016	11	78	46

Fonte: Autor.

3.4 Análise das Publicações por País

A partir do conjunto de dados considerado, é possível analisar a segmentação geográfica das publicações de programas de DR baseados em tarifas/preços. Assim, por meio da Figura 7, pode-se visualizar o *ranking* dos 10 países academicamente mais ativos neste campo de pesquisa, destacando Estados Unidos e China como maiores produtores nesta área, com evidente diferença em relação aos demais.

Figura 7: Países mais produtivos na área de DR, em relação aos programas baseados em tarifas/preços.



Fonte: Autor.

Na Tabela 4, é possível analisar toda a relação de produtividade por país, a qual foi elaborada neste levantamento. Nesta relação, composta por 36 países, o Brasil, aparece na posição 35, evidenciando uma clara necessidade de envolvimento da área acadêmica local a fim de explorar o tema e, a partir destas pesquisas, oferecer e produzir insumos científicos relevantes que possam beneficiar a sociedade brasileira.

Tabela 4: Números de publicações sobre programas de DR baseados em tarifas/preços por país.

País	Artigos	País	Artigos
Estados Unidos	145	África do Sul	5
China	82	Suécia	5
Irã	37	Suécia	5
Coréia	36	Finlândia	4
Reino Unido	22	França	4
Canadá	19	Grécia	4
Índia	11	Paquistão	4
Itália	11	Turquia	4
Japão	9	Hong Kong	3
Singapura	9	Tailândia	3
Dinamarca	8	Irlanda	2
Austrália	7	México	2
Holanda	7	Nova Zelândia	2
Espanha	7	Portugal	2
Bélgica	6	Arábia Saudita	2
Alemanha	6	Áustria	1
Malásia	6	Brasil	1
Taiwan	6	Egito	1

Fonte: Autor.

Por fim, no que tange a análise das publicações por países, a Tabela 5 apresenta a relação de citações por artigo para cada país. Neste sentido, os Estados

Unidos aparecem como primeiro colocado, tendo larga vantagem em número total e média de citações em relação aos demais países. No entanto, diferente da análise anterior, nessa tabela, o Canadá aparece na 2ª posição e a China se torna a 3ª, indicando um interessante fator de relevância nos trabalhos canadenses na área de programas de DR baseados em tarifas/preços, visto que a partir da Tabela 4, este país ocupava apenas a 6ª posição no indicador de produtividade, com apenas 19 publicações na área.

Tabela 5: Números de Citações por País.

País	Citações	Média por Artigo	País	Citações	Média por Artigo
EUA	2934	20,234	Alemanha	62	10,333
Canadá	978	51,474	Grécia	62	15,500
China	743	9,061	Índia	57	5,182
Espanha	595	85,000	Taiwan	56	9,333
Áustria	588	588,000	Suíça	49	9,800
Reino Unido	555	25,227	Irlanda	47	23,500
Irã	548	14,811	França	30	7,500
Turquia	348	87,000	Nova Zelândia	29	14,500
Coréia	271	7,528	Egito	22	22,000
Dinamarca	206	25,750	Austrália	16	2,286
Holanda	179	25,571	Brasil	16	16,000
Portugal	134	67,000	Tailândia	10	3,333
Hong Kong	119	39,667	Malásia	9	1,500
Itália	110	10,000	Paquistão	7	1,750
Bélgica	103	17,167	México	6	3,000
Singapura	102	11,333	Finlândia	4	1,000
Suécia	81	16,200	Japão	2	0,222
África do Sul	66	13,200	Ar. Saudita	0	0,000

Fonte: Autor.

Diante de um refinamento de busca de pouco mais de 500 artigos científicos e *reviews* indexados na base de dados *Scopus*, no período entre 2006 a 2016, indicadores bibliométricos e de conteúdo foram desenvolvidos a fim de tornar mensurável a produção científica e os caminhos que este campo acadêmico vem percorrendo ao longo dos anos. Assim, foram aplicados três indicadores. Suas respectivas interpretações são apresentadas na sequência.

Existe um crescimento considerável no número de publicações acadêmicas sobre programas de *Demand Response* baseados em tarifas/preços, sobretudo a partir de 2009. Esse interesse se baseia na evolução das tecnologias da informação nos últimos anos, que potencializaram assim a implementação das *Smart Grids*, as quais viabilizam a gestão eficiente de energia perante todos os envolvidos neste cenário, desde a geração até o consumo final.

Em relação aos três tipos de modelos de tarifação mais populares em programas de *Demand Response* baseados em tarifas/preços, observa-se um amplo domínio em trabalhos sobre RTP, com 63,7% do total dos trabalhos contemplados. Em menor número, TOU categoriza 27,1% dos artigos deste levantamento e trabalhos sobre CPP representam apenas 9,2%, pelo fato deste último consistir em um modelo híbrido entre os anteriores.

Estados Unidos e China com 145 e 82 artigos publicados, respectivamente, são os países que mais contribuem neste campo de pesquisa. Em contrapartida, o Brasil, por exemplo, aparece na lista de países menos ativos em pesquisa sobre programas de *Demand Response* baseados em tarifas/preços. Em tempo, vale citar que o Canadá, mesmo sendo o 6º país em termos de números totais de publicação, é o segundo país que mais possui citações, o que pode indicar que seus trabalhos possuem grande relevância neste meio.

Capítulo 4

MODELAGEM DO PROBLEMA E MÉTODOS DE OTIMIZAÇÃO

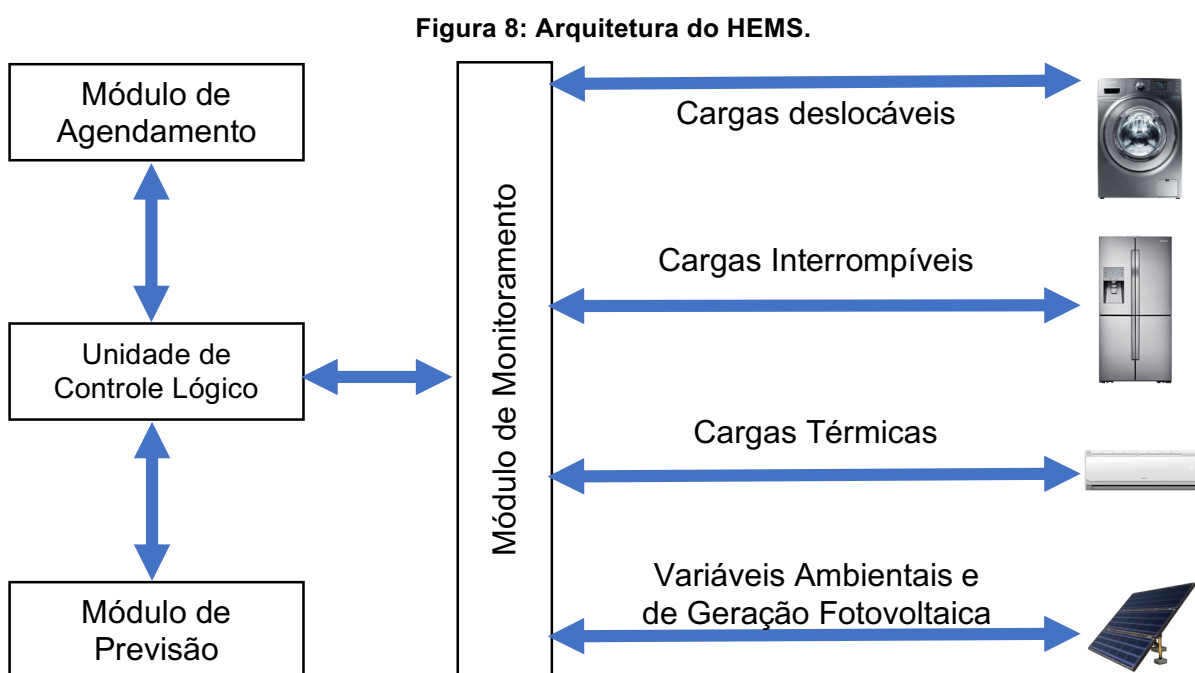
Para o desenvolvimento de *Smart Grids*, técnicas eficientes de análise e otimização se fazem importantes ao permitir a transformação de uma grande base de dados em informações compreensíveis. O presente capítulo apresentará a modelagem do problema, bem como uma breve explanação sobre técnicas heurísticas e meta-heurísticas, que permite uma implementação eficiente de ações que considerem o consumidor como um agente ativo do sistema elétrico.

4.1 Modelo Matemático

Com base em técnicas computacionais adequadas e a partir de modelos matemáticos que representem as cargas e o perfil de consumidores residenciais, pode-se maximizar as vantagens de aderir aos programas de DR. Logo, a escolha destes modelos pondera diferentes fatores relacionados ao consumo de energia elétrica, resultando em particularidades importantes a serem consideradas no problema de otimização.

A partir do trabalho de HUANG, TIAN e WANG (2015), esta dissertação adota uma modelagem matemática para programas de DR que permite implementar um sistema de gerenciamento de energia elétrica residencial (do inglês, *Home Energy Management System* – HEMS).

Conforme pode ser visto na Figura 8, é assumido que a maioria dos dispositivos elétricos estão conectados entre si e são controlados pelo sistema de gerenciamento de energia.



Fonte: Adaptado de HUANG, TIAN e WANG (2015).

Segundo CHO (2013), uma residência pode ser considerada 'inteligente' (ou seja, adaptada ao contexto de SG) caso possua um gerador fotovoltaico, dispositivos de armazenamento de energia e aparelhos elétricos que sejam flexíveis de ajustar sua operação de funcionamento diante de variáveis financeiras e ambientais.

Logo, conforme a Figura 8, um HEMS contém quatro componentes principais: um módulo de agendamento, um módulo de previsão, uma unidade de controle lógico e um módulo de monitoramento. O comportamento das cargas é registrado pelo módulo do monitoramento e a potência da geração de energia fotovoltaica é calculada pelo módulo de previsão, de acordo com os dados ambientais e demais informações da rede elétrica. O módulo de agendamento, parte essencial da arquitetura do HEMS, calcula a programação da operação das cargas. Após o processo de otimização do agendamento, a unidade de controle lógico envia os horários ideais planejados às cargas e controla diretamente aquelas que sejam interrompíveis, bem como os dispositivos térmicos presentes na residência.

Portanto, todo o contexto de planejamento de operação das cargas e utilização de dispositivos de armazenamento de energia elétrica é tido como um complexo problema de otimização, levando à necessidade de formalizar matematicamente o comportamento e restrições de todos componentes considerados neste processo.

4.1.1 Função Objetivo

O objetivo do módulo de agendamento no HEMS é determinar os melhores horários de operação para as cargas e a quantidade de carga ou descarga do banco de energia para cada instante de tempo do horizonte de planejamento diário, a fim de minimizar o custo da eletricidade consumida considerando as restrições físicas das cargas. Portanto, a função objetivo é expressa da seguinte forma:

$$\text{Minimizar } \mathbf{Custo} = \sum_{h=1}^{24} [TOU(h) * P_{grid}(h)]. \quad (1)$$

Como pode ser observado na Equação (1), é assumido que o preço da energia $TOU(h)$ cobrado pela concessionária é conhecido *a priori* para cada hora do dia, possuindo este uma estrutura tarifária do tipo TOU. Além disso, existe uma restrição de troca de energia entre a residência e a rede elétrica de abastecimento (*grid*). Os valores positivos para $P_{grid}(h)$ representam a quantidade de energia comprada da rede na hora h , e os valores negativos representam a energia excedente vendida para a rede na hora h .

4.1.2 Restrições de Cargas

Neste modelo, conforme previamente descrito, assume-se que $P_{grid}(h)$ é a quantidade de energia que a residência compra ou vende à rede. Logo, a relação de balanço da energia é mantida conforme estabelecido na Equação (2). Os aparelhos elétricos podem ser divididos em dois tipos: com operação fixa ou operação escalável. Assume-se que as cargas fixas não são passíveis de agendamentos, enquanto aparelhos eletrodomésticos escaláveis e/ou térmicos possuem flexibilidade de ajustar suas operações dentro do horizonte de planejamento a fim de evitar horários de pico.

$$P_{grid}(h) = P_{bat}(h) + P_{fix}(h) + P_{term}(h) + P_{flex}(h) - P_{pv}(h). \quad (2)$$

Para cada hora do dia, $P_{fix}(h)$ indica o consumo total de energia das cargas fixas. $P_{term}(h)$ e $P_{flex}(h)$ representam o consumo energético de aparelhos térmicos e eletrodomésticos escaláveis, respectivamente. $P_{bat}(h)$ refere-se à energia armazenada na bateria e $P_{pv}(h)$ é a energia fotovoltaica gerada pela residência.

Nesta dissertação, apoiado no trabalho dos autores que propuseram o modelo matemático em questão, a bateria residencial é um veículo elétrico híbrido (PHEV, do inglês *Plug-in Hybrid Electric Vehicle*) e está sempre conectado (e disponível) à residência. A bateria, portanto, pode ser carregada ou descarregada em resposta a diferentes condições, podendo se adaptar a momentos de pico tarifário, utilizando assim a energia residencial de modo mais eficiente.

Dado o comportamento dinâmico da bateria, os processos de carga e descarga são limitados, tal que – conforme as Equações (3) e (4) – existem limites máximos para carga ou descarga da bateria, que devem ser respeitados durante sua utilização. Os fatores η_{cg} e η_{dcg} dizem respeito à eficiência da bateria durante ciclos de carga e descarga. Ainda, visando garantir a operação da bateria de modo sustentável, a restrição do estado da bateria (SOC, do inglês *State of Charging*) deve ser considerada, uma vez que preserva a vida útil do dispositivo de armazenamento.

$$0 \leq \frac{P_{bat}^{cg}}{\eta_{cg}} \leq P_{cg}^{max}, \quad (3)$$

$$0 \leq P_{bat}^{dcg} * \eta_{dcg} \leq P_{dcg}^{max}. \quad (4)$$

Quando o nível de SOC atinge um limiar máximo (SOC^{max}), não é permitido armazenar mais energia na bateria. O mesmo ocorre quando SOC está atingido um limiar mínimo (SOC^{min}), proibindo a utilização da energia adicional presente na bateria, conforme descrevem as Equações e Restrições (5), (6) e (7). Em tempo, E_{bat} se refere à capacidade total de armazenamento da bateria.

$$P_{bat}(h) = \frac{P_{bat}^{cg}}{\eta_{cg}} = P_{bat}^{dcg} * \eta_{dcg}, \quad (5)$$

$$SOC(h + 1) = SOC(h) + \frac{P_{bat}^{cg} - P_{bat}^{dcg}}{E_{bat}}, \quad (6)$$

$$SOC^{min} \leq SOC(h) \leq SOC^{max}. \quad (7)$$

Em relação aos aparelhos térmicos, deve-se contemplar restrições quanto à temperatura ambiente da residência, a qual influencia diretamente suas operações. Neste sentido, esta variável é obtida por meio Equação (8) e restrição (9):

$$\begin{aligned} T_{amb}(h + 1) &= T_{amb}(h) * e^{-\frac{\Delta}{\tau}} \\ &+ \left(R * P_{term}(h) * T_{ext}(h) * \left(1 - e^{-\frac{\Delta}{\tau}} \right) \right), \end{aligned} \quad (8)$$

$$T_{amb}^{min} \leq T_{amb}(h) \leq T_{amb}^{max}, \quad (9)$$

onde $\Delta = 1h$ e $\tau = RC$. Os valores de R e C adotados foram $18^\circ\text{C}/kW$ e $0,525 kWh/^\circ\text{C}$, respectivamente. Ainda, a temperatura ambiente inicial considerada foi 20°C , sendo que devem ser respeitados os limiares mínimo e máximo para a temperatura gerenciada pelos aparelhos térmicos, conforme a restrição imposta na Equação (9).

Por fim, os diferentes tipos de aparelhos elétricos escaláveis possuem distintas restrições de operação que os diferem entre si. Mais precisamente, define-se neste modelo tais aparelhos em dois tipos: cargas interrompíveis e não-interrompíveis.

No primeiro tipo, de cargas interrompíveis, assume-se que os aparelhos possuem dois estados, ligado ou desligado. Uma vez ligado, o aparelho deste tipo deve funcionar, com sua respectiva potência nominal P_a , durante H horas dentro do intervalo de tempo $[\alpha_a, \beta_a]$, não necessitando que estas horas sejam sequenciais neste intervalo, de modo que totalize o consumo E_a de energia planejado *a priori* para

este aparelho. Portanto, a otimização do planejamento da operação destes aparelhos deve respeitar as seguintes restrições:

$$\delta_{a,t} = 0 \quad t \notin [\alpha_a, \beta_a], \quad (10)$$

$$\sum_{t=\alpha_a}^{t_0} \delta_t + \delta_{t_0} + \sum_{\tau=t_0+1}^{\beta_a} \delta_\tau = H, \quad (11)$$

$$\sum_{t=\alpha_a}^{\beta_a} \delta_t * P_a = E_a. \quad (12)$$

A restrição (10) define que o agendamento do aparelho deve ser restrito ao intervalo de início e término pré-estabelecidos. Já as restrições (11) e (12) delimitam a operação da carga do aparelho, na qual a execução completa deve respeitar a janela de planejamento $[\alpha_a, \beta_a]$ e totalizar o consumo planejado durante sua execução, respectivamente.

Por fim, aparelhos não-interrompíveis operam de forma contínua dentro de um intervalo de tempo, ou seja, uma vez acionados devem continuar ligados até o fim de sua operação sem interrupção, conforme as restrições:

$$\sum_{t=\alpha_i}^{t_0-1} \delta_t + \delta_{t_0} + \sum_{\tau=t_0+1}^{\alpha_i+\lambda_i} \delta_\tau \geq 1, \quad (13)$$

$$\sum_{\tau=t_0+1}^{t_0+H} \delta_\tau \geq H * (\delta_{t_0+1} - \delta_{t_0}), \quad (14)$$

$$\sum_{t=\alpha_a}^{\beta_a} \delta_t = H \quad t \in [\alpha_a, \beta_a]. \quad (15)$$

A restrição (13) indica que o início de operação de um aparelho deste tipo deve estar dentro de um intervalo válido $[\alpha_i, \alpha_i + \lambda_i]$, onde o termo λ_i é um limite tolerável de atraso para o início do acionamento da carga. Já a restrição (14) denota o

comportamento não-interrompível para a operação, e a restrição (15) delimita o funcionamento do aparelho a possuir uma duração máxima de H horas, respeitando a janela de planejamento $[\alpha_a, \beta_a]$.

Deste modo, a modelagem matemática descrita permite otimizar o horizonte de planejamento diário de uma residência, contemplando o objetivo de minimização do custo proveniente do consumo de energia – premissa fundamental em programas de DR – e as restrições dos diferentes tipos de cargas presentes. Vale ressaltar que este arcabouço matemático permite realizar simulações próximas à realidade residencial em qualquer escala no contexto de SG. No que tange a complexidade, a modelagem matemática aqui descrita pertence à classe de problemas MINLP (do inglês, *Mixed-Integer Non-Linear Programming*), na qual o espaço de soluções possui uma mescla de dimensões binárias e reais, além de contemplar restrições não lineares inerentes ao objetivo adotado, sendo classificado como NP-Difícil (BURER e LETCHFORD, 2012).

Para problemas que não são formulados como de otimização convexa, segundo HUANG, TIAN e WANG (2015), métodos exatos podem não encontrar uma solução factível ou o tempo computacional exigido para este fim pode ser elevado. Ainda, GOLDBARG, GOLDBARG e LUNA (2016) destacam que tais métodos enfrentam um desafio para fornecer soluções exatas para problemas NP-Difícil, uma vez que são suscetíveis à exigir consumo exponencial de tempo e recursos computacionais em função do tamanho da entrada de dados do problema. Corroborando com esta afirmação, LIU (2016) prova que os problemas de gestão de carga, que visam minimizar o custo devido ao consumo de energia elétrica e a suavização da curva de carga do sistema, são classificados como problemas NP-Difícil.

Portanto, a aplicação de técnicas meta-heurísticas – como o algoritmo PSO –, que implementem mecanismos para lidar com a complexidade das restrições a fim de delimitar a exploração do espaço de busca factível, se mostra coerente para a resolução do problema de otimização estabelecido nesta dissertação.

4.2 Heurísticas

O conceito de heurística é amplo e, segundo GOLDBARG, GOLDBARG e LUNA (2016), pode ser descrito como “um atalho mental que permite às pessoas resolver problemas e fazer julgamentos rápidos e eficientes”. Segundo os autores, no contexto computacional, define-se uma heurística como um algoritmo que visa alcançar uma solução otimizada de problemas NP-Difícil ou mais complexos, considerando um esforço computacional razoavelmente factível. Os autores destacam ainda que mesmo para problemas complexos em que existem algoritmos exatos eficientes conhecidos, dependendo do tamanho da entrada de dados e do tempo computacional disponível, o uso de métodos heurísticos não pode ser descartado. Além disso, as heurísticas têm a seu favor a facilidade de implementação frente aos métodos exatos tradicionais. Essa característica torna-se bastante útil para sistemas a serem embarcados em hardware.

Entretanto, embora algoritmos embasados em técnicas heurísticas tenham se provado eficientes em muitos problemas e se beneficiado do crescente poder computacional ao longo dos anos, tais métodos são relativamente frágeis quanto à execução dos seus procedimentos, pois em geral aplicam o conceito de tentativa e erro, tendendo a não escaparem de soluções ótimas locais (LUZIA e RODRIGUES, 2009).

Neste contexto, surgem as heurísticas modernas ou, como amplamente difundido, meta-heurísticas. Embora tais métodos compartilhem dos mesmos objetivos que procedimentos heurísticos, são algoritmos mais flexíveis em sua concepção e implementação, mantendo a característica fundamental de não fazer uso excessivo dos recursos computacionais em seu processo de resolução.

4.3 Meta-heurísticas

Meta-heurísticas surgiram em meados da década de 80 em um estudo que combinava métodos heurísticos básicos cujo objetivo também era encontrar soluções em problemas de otimização combinatória (GLOVER, 1986).

Uma meta-heurística, segundo VOS *et al.* (1999), pode ser definida como um procedimento iterativo que guia e modifica operações das heurísticas que lhe são subordinadas de forma a, eficientemente, produzir soluções otimizadas de um determinado problema de alta complexidade. Ainda, OSMAN e LAPORTE (1996) afirmam que estas técnicas visam, através da combinação de métodos heurísticos, explorar e explorar o espaço de busca. Estas duas características são de fundamental importância no projeto de uma meta-heurística, uma vez que a exploração busca varrer – diversificar – o espaço de busca, enquanto a exploração tem o objetivo de examinar uma dada região e sua vizinhança no espaço de busca à procura de mínimos locais (GOLDBARG, GOLDBARG e LUNA, 2016).

Em geral, as meta-heurísticas podem ser diferenciadas pelas seguintes características em sua implementação:

- Se apoiar em decisões gulosas, que por vezes geram boas soluções iniciais;
- Utilizar buscas locais por meio de estratégias determinísticas;
- Mimetizar procedimentos naturais para obter solução no espaço de busca, como por exemplo a simulação dos mecanismos de mutação genética ou até do comportamento de enxame de abelhas.

CHAVES (2009) cita alguns exemplos de algoritmos classificados como meta-heurísticas: Otimização por Colônia de Formigas (ACO, do inglês *Ant Colony Optimization*), Algoritmo Genético (GA), Busca Tabu (TS, do inglês *Tabu Search*), Recozimento Simulado (SA, do inglês *Simulated Annealing*), Pesquisa em Vizinhança Variável (VNS, do inglês *Variable Neighborhood Search*) e Busca Local Iterativa (ILS, do inglês *Iterated Local Search*).

Técnicas meta-heurísticas possuem grande flexibilidade de implementação, as quais permitem combinar diferentes abordagens heurísticas e determinísticas a fim de lidar com problemas de otimização complexos, mitigando a possibilidade de obtenção de soluções mínimas locais. Logo, tais técnicas, as quais serão utilizadas neste trabalho, representam abordagens viáveis e realistas para a resolução do problema de DR, mais precisamente organizando o planejamento de operação de cargas em larga escala, tendo como objetivo minimizar o custo relativo ao consumo de energia elétrica de consumidores em uma SG.

4.4 Otimização por Enxame de Partículas

Nesta subseção serão apresentados os métodos de otimização utilizados no desenvolvimento deste trabalho, tendo como principal objetivo, conforme amplamente discutido nas seções anteriores, a implementação de algoritmos da classe de meta-heurísticas para a resolução do problema de DR. Portanto, foi escolhido o algoritmo de Otimização por Enxame de Partículas, PSO, para realizar a gestão de cargas do conjunto de residências. Essa escolha foi motivada pela capacidade do método em gerar soluções otimizadas em prazos gerenciáveis, isto é, com o intuito de garantir um equilíbrio entre resultado robusto e esforço computacional adequado à aplicação.

4.4.1 Fundamentos

O algoritmo de PSO, segundo GOLDBARG, GOLDBARG e LUNA (2016), é uma técnica computacional evolutiva que foi desenvolvida inspirando-se no comportamento de enxames de animais, como aves e abelhas, que utilizam a inteligência do enxame a fim de garantir sua sobrevivência. Neste sentido, o PSO busca resolver, de forma heurística, um problema de otimização diante de uma medida de qualidade pré-estabelecida. Assim, a solução de um problema, ou uma partícula, é encontrada dentro de um enxame contendo um número fixo de partículas. Com suas coordenadas, cada partícula possui um registro de suas melhores aptidões (*fitness*) já vivenciadas, denominada *pBest*, bem como a melhor aptidão global do enxame, denominada *gBest*. Portanto, o enxame se move sempre em direção às melhores soluções encontradas, mimetizando o comportamento de um bando de aves no processo migratório.

A posição de uma partícula no voo é determinada com base em sua posição anterior, $P_i(X_1, \dots, X_n)$, e também por sua velocidade, $V_i(V_1, \dots, V_n)$, de modo que $\{X_1, \dots, X_n\}$ são as coordenadas da partícula. Portanto, o movimento do enxame é regido pelas Equações (16) e (17):

$$V_i^{(t+1)} = V_i^t + \varphi_1 rand() (X_{pBest,i}^t - X_i^t) + \varphi_2 rand() (X_{gBest,i}^t - X_i^t), \quad (16)$$

$$X_i^{(t+1)} = X_i^t + V_i^{(t+1)}, \quad (17)$$

onde $V_i^{(t+1)}$ é a velocidade da i -ésima partícula na próxima iteração, V_i^t é a atual velocidade dessa partícula, $X_i^{(t+1)}$ é a coordenada de posição na próxima iteração, X_i^t é a coordenada atual de posição na iteração corrente t , $X_{pBest,i}^t$ e $X_{gBest,i}^t$ são respectivamente as melhores coordenadas para a partícula i e para todo o enxame, φ_1 é o fator que pondera a exploração local (parâmetro cognitivo) e φ_2 a exploração global (parâmetro social) e, por fim, $rand()$ é um valor aleatório uniformemente distribuído entre 0 e 1 (EBERHART e KENNEDY, 1995; GOLDBARG, GOLDBARG e LUNA, 2016).

Após o cálculo da Equação (16), o indivíduo já está pronto para se deslocar no espaço de busca, movimentação esta consumada por meio da Equação (17). Para garantir que o PSO irá gerar soluções viáveis ao contexto do problema que será otimizado, se faz necessário implementar um mecanismo que vise impor limites mínimos e máximos às velocidades das partículas, de modo que cada dimensão d do espaço de busca seja regido com base na seguinte regra:

$$\begin{aligned} & \textbf{Se } X_i > \max(X_i) \textbf{ Então } X_i = \max(X_i) \\ & \textbf{Senão Se } X_i < \min(X_i) \textbf{ Então } X_i = \min(X_i). \end{aligned}$$


Conforme pode ser observado na Figura 9, diante das equações apresentadas, o enxame possui a capacidade de explorar o espaço do problema, convergindo para uma solução otimizada.

Três princípios são elucidados por EBERHART e KENNEDY (1995) para descrever o processo de exploração do PSO rumo à solução ótima global, o qual os autores nomeiam como aprendizado, sendo estes:

- Avaliação – os agentes possuem a capacidade de mensurar o ambiente a fim de estimar seu próprio comportamento;
- Comparação – os agentes compartilham informações mutuamente para estabelecer referências comparativas dentro do enxame;

- Imitação – com base no comportamento social, mimetiza informações que julga relevante dentre os melhores agentes, característica importante para a aquisição e manutenção das habilidades cognitivas, principalmente em organizações sociais humanas.
-

Figura 9: Comportamento Exploratório do Enxame Rumo à Solução Otimizada.



Fonte: Autor.

Estas características, segundo os autores, atribuem ao algoritmo a capacidade de encontrar soluções globais, uma vez que os indivíduos são inicializados aleatoriamente e, ao trocar informações com seus vizinhos próximos ou serem influenciados pela melhor solução encontrada, migram no espaço de busca, conforme definem as Equações (16) e (17). Como a intensidade do deslocamento no espaço de busca também é aleatória, é garantido o caráter global de otimização.

Pseudocódigo 1: PSO.

-
- 1: Definir o número de partículas P do enxame;
 - 2: Inicializar aleatoriamente a posição x de cada partícula $p \in P$;
 - 3: Atribuir uma velocidade inicial v igual para todas as partículas;
 - 4: **Para** cada $p \in P$ **faça**:
 - a. Calcule a aptidão $f(p)$;
-

-
- b. Define a melhor posição da partícula até o momento (pBest);
 - c. Descobrir a partícula com a melhor aptidão no enxame (gBest);
- 5: **Para** cada $p \in P$ **faça**:
- a. Atualizar a velocidade da partícula (Equação 16);
 - b. Atualizar a posição da partícula (Equação 17);
- 6: **Se** a condição de término não for alcançada **então**:
- a. Voltar ao Passo 4.
-

Fonte: Autor.

Conforme pode ser observado no Pseudocódigo 1, o ciclo de execução do algoritmo PSO é repetido até que um critério de parada seja satisfeito ou quando a estagnação das velocidades das partículas for constatada, ou seja, quando nenhuma mudança relevante estiver ocorrendo.

4.4.2 PSO com Fator de Inércia Decrescente

Como evolução à abordagem supracitada, SHI e EBERHART (1999) propuseram uma versão do PSO na qual o cálculo da equação de velocidade (16) leva em consideração um novo argumento, o qual denominam por fator de inércia. Este fator possui valor linearmente decrescente, originando assim uma nova estratégia de otimização por enxame de partículas, denominada LDW-PSO (do inglês, *Linear Decreasing Weight Particle Swarm Optimization*). Os autores demonstram que esta nova abordagem aumenta significativamente o desempenho do algoritmo em relação ao PSO clássico em muitos casos analisados, pois o decréscimo linear do fator de inércia equilibra de forma eficaz a capacidade de exploração local e global do enxame. No LDW-PSO, w é o fator de inércia, o qual decresce linearmente sob valores máximo e mínimo pré-estabelecidos. Logo, conforme XIA e WU (2005), o valor do fator de inércia w é obtido pela Equação (18):

$$w = w_{max} - \frac{w_{max} - w_{min}}{iter_{max}} iter, \quad (18)$$

onde w_{max} representa o valor máximo que o fator de inércia pode obter, w_{min} é o respectivo valor mínimo, $iter_{max}$ é o número máximo de iterações que o PSO irá executar e $iter$ se refere à iteração corrente do algoritmo. Com isto, a nova equação de velocidade do LDW-PSO, derivada da Equação (16) do PSO clássico é dado por:

$$V_i^{(t+1)} = wV_i^t + \varphi_1 rand() (X_{pBest,i}^t - X_i^t) + \varphi_2 rand() (X_{gBest,i}^t - X_i^t). \quad (19)$$

Segundo SHI e EBERHART (1999), um grande valor para o fator de inércia facilita a exploração global do espaço de busca, enquanto um valor pequeno facilita a exploração local. Por isso, os autores argumentam que ao diminuir linearmente o fator de inércia, partindo de um valor relativamente grande para um valor pequeno ao longo das iterações do algoritmo, o PSO tende a ter maior capacidade de busca global no início da execução e também maior capacidade de exploração local perto do fim das execuções.

4.4.3 PSO com Fator de Constrição

As técnicas de otimização, como se sabe, são parte crucial nos processos de planejamento, operação e controle dos sistemas de energia elétrica. No entanto, muitos problemas de otimização neste domínio são complexos por natureza, uma vez que possuem elevado número de restrições a serem respeitadas e enfrentam problemas relacionados à alta dimensionalidade, falta de informações, dados ruidosos e corrompidos, bem como requisitos de operação em tempo real (ou em alguns casos em milissegundo ou microssegundo) (GELLINGS, 2009).

Para mitigar os fenômenos de convergência prematura ou divergência que ocorrem com frequência no processo de otimização com o uso do algoritmo PSO – especialmente em problemas desta natureza – e também para melhorar a velocidade e a eficácia do mesmo, muitos tipos alteração do algoritmo em questão foram introduzidos na literatura.

Um alterações mais representativas é a adoção do fator de constrição (χ) na equação de atualização da velocidade do enxame, proposta por CLERC e KENNEDY (2002). Esta nova equação contempla um fator de amortecimento baseado nos parâmetros cognitivo e social (φ_1 e φ_2 , respectivamente) para limitar a velocidade das

partículas. O PSO com fator de constrição pode atingir, segundo os autores, uma solução factível rapidamente, uma vez que restringindo a velocidade permite-se que o enxame explore de modo mais metuculoso o espaço de busca.

$$V_i^{(t+1)} = \chi[V_i^t + \varphi_1 \text{rand}() (X_{pBest,i}^t - X_i^t) + \varphi_2 \text{rand}() (X_{gBest,i}^t - X_i^t)], \quad (20)$$

$$\chi = \frac{2\kappa}{|2 - \phi - \sqrt{\phi^2 - 4\phi}|}, \quad (21)$$

$$\phi = \varphi_1 + \varphi_2, \quad \phi > 4. \quad (22)$$

INNOCENTE e SIENZ (2011) citam que esta versão de PSO se tornou muito popular por, além de apresentar grande eficiência, manter em grande parte a estrutura básica do PSO clássico, adotando alterações mínimas e intuitivas em suas equações, conforme pode ser visto nas Equações (20) e (21). Observa-se na Equação (20) que a velocidade é ponderada pelo fator de constrição χ , o qual tem objetivo de restringir a exploração do espaço de busca, sendo que este fator é calculado conforme as Equações (21) e (22). Em geral, um fator de constrição $\chi \simeq 0.73$ ($\kappa = 1$, $\phi = 4.1$) apresenta grande eficácia em uma ampla gama de testes realizados pelos autores.

4.4.4 PSO com Inércia Individualizada e Adaptativa

Várias aplicações necessitam de implementação de soluções que ofereçam rápido processamento na resolução de problemas, sendo desejável a obtenção de respostas quase em tempo real, como em linhas de produção ou no problema de otimização de DR aqui discutido. Neste contexto, os pesquisadores Ricardo Fernandes e Guilherme Spavieri do Laboratório de Inteligência Artificial Aplicada (LIAA) da UFSCar propuseram um mecanismo de inércia adaptativo (ainda não publicado) onde, levando em consideração as equações de atualização de velocidade (Equações (19)) e posição (Equações (17)), o fator de inércia, o mesmo é calculado considerando análises globais (desempenho da melhor e pior partículas) e individuais

(desempenho da própria partícula) do enxame. Portanto, a inércia neste mecanismo é obtida da seguinte forma:

$$w_i^{t+1} = w_{min} + (w_{max} - w_{min}) * \frac{(f_i^t - f_{pior}^t)}{(f_{melhor}^t - f_{pior}^t)}, \quad (23)$$

onde i denota a i -ésima partícula (indivíduo), t se refere à t -ésima iteração do PSO, f_i^t é o valor do *fitness* do i -ésimo indivíduo na t -ésima iteração e f_{melhor}^t e f_{pior}^t são, respectivamente, o melhor e pior valores de *fitness* dentre todo o enxame na iteração t do algoritmo.

Segundo os autores, a distribuição da inércia do enxame é linearmente disposta em função do pior e do melhor valor de *fitness* na iteração atual e, diferentemente dos outros mecanismos que lidam com o fator de inércia, o valor do fator de inércia não é uma constante, aleatório ou um valor diretamente dependente do número da iteração. Neste mecanismo, as partículas que têm a melhor aptidão na iteração atual receberão os pesos de inércia mais altos na próxima iteração, de modo que tendem a manter a movimentação na melhor direção de busca atual. Por outro lado, as partículas que têm o pior *fitness* na iteração atual serão as que receberão os menores valores de peso de inércia na próxima iteração, sendo, portanto, encorajadas a mudar sua direção. Assim, as direções de busca preferíveis serão aquelas seguidas pelas partículas com os melhores valores da função objetivo.

Por fim, em testes preliminares considerando diversas funções não-lineares e funções de *benchmark*, foi possível observar que as modificações propostas (ou seja, a inércia adaptativa individualizada) tornaram a convergência do algoritmo de PSO mais rápida quando comparada ao mesmo algoritmo com outros mecanismos de inércia.

4.4.5 PSO Binário

Problemas como o escalonamento de recursos, em geral, exigem uma habilidade especial dos métodos de otimização em lidar com a melhor distribuição dentro do horizonte de planejamento. Por exemplo, considerando o planejamento da operação de aparelhos elétricos discutido nesta dissertação, deve-se descobrir qual o

melhor horário para acionar ou desligar um aparelho em função do custo da energia cobrada, de modo que considere o acúmulo de carga dos demais aparelhos e satisfaça as restrições do problema. A fim de modelar tal cenário, diversos estudos apontam a adoção de variáveis de decisão binárias (0 ou 1, 'ligado' ou 'desligado') como uma representação eficiente para implementação em técnicas como o PSO.

Todavia, conforme já discutido, este algoritmo foi proposto inicialmente para contemplar a otimização em um espaço de variáveis reais, o que inviabiliza sua implementação canônica em representações binárias. A fim de mitigar tal impedimento, KENNEDY e EBERHART (1997) propuseram uma versão do PSO capaz de operar em espaço discreto, mantendo grande parte das ideias gerais de sua versão canônica, apenas adotando uma estratégia distinta para a atualização da posição $X_i^{(t+1)}$.

$$\begin{aligned} \textit{Se } rand() < \textit{Sigmoid} \left(V_i^{(t+1)} \right) \textit{Então } X_i^{(t+1)} &= 1 \\ \textit{Senão } X_i^{(t+1)} &= 0 \end{aligned} \quad (24)$$

$$\textit{Sigmoid} \left(X_i^{(t+1)} \right) = \frac{1}{1 + e^{-X_i^{(t+1)}}}. \quad (25)$$

Como pode ser observado na Equação (24), as posições $X_i^{(t+1)}$ do enxame são atualizadas com base na probabilidade de uma coordenada assumir um valor 0 ou 1, considerando a função que faça a transformação da velocidade real em um valor binário. Em geral, segundo os autores, a função *Sigmoid*, disposta na Equação (25), é a mais empregada para este fim.

Logo, o funcionamento do PSO binário se mantém simples. Calcula-se o valor da *Sigmoid* para a velocidade $V_i^{(t+1)}$. Se este valor calculado for menor que um número aleatório uniformemente distribuído, a nova posição assume um valor 1, caso contrário, assume valor 0. Dada a característica da função *Sigmoid*, os autores citam que a adoção de uma estratégia de limitação inferior e superior $[V^{min}, V^{max}]$ da velocidade auxilia na convergência deste algoritmo.

4.5 Aplicação em Problemas Complexos

A modelagem matemática tem sido utilizada para o estudo e compreensão de muitos problemas e fenômenos reais nas mais diversas áreas do conhecimento, como na engenharia, economia, medicina, entre outras. Neste sentido, conforme GOLDBARG, GOLDBARG e LUNA (2016), a complexidade de um determinado problema pode ser mensurada de acordo com, entre outros fatores, a presença de restrições não lineares e a escala do espaço de busca, por exemplo. Assim, se faz necessário um estudo cuidadoso destas características a fim de implementar uma abordagem eficiente para a resolução de problemas desta natureza.

4.5.1 Problemas com Restrições

Um problema de otimização que contemple restrições apresenta a seguinte estrutura matemática:

$$\text{Encontrar um } x \text{ que minimize } f(x) \quad (26)$$

sujeito a

$$l_j \leq g_j(x) \leq u_j, \quad j = 1, 2, \dots, n_g \quad (27)$$

$$h_k(x) = e_k, \quad k = 1, 2, \dots, n_h \quad (28)$$

$$x_i^L \leq x_i \leq x_i^U, \quad i = 1, 2, \dots, n \quad (29)$$

onde x é uma solução candidata, $f(x)$ é a função objetivo a ser minimizada, $g_j(x)$ são as restrições de desigualdade (com seus respectivos limites mínimo l_j e máximo u_j), $h_k(x)$ são as restrições de igualdade ao valor de e_k e a Equação (29) denota os limites mínimo (x_i^L) e máximo (x_i^U) das variáveis do projeto impostas nas dimensões do vetor solução x . Em tempo, n , n_g e n_h representam os números de restrições de desigualdade, igualdade e de dimensões do problema, respectivamente.

Considerando a modelagem matemática de problemas existentes no mundo real, os problemas de otimização com restrições são abundantes e lidar com estas

restrições é um dos maiores desafios para a eficiente aplicação de algoritmos evolutivos. Assim, diversas abordagens que atacam especificamente estes tipos de problemas têm sido propostos durante anos.

4.5.1.1 Penalização da Função Objetivo

Proposta originalmente por COURANT (1943), uma das abordagens mais comuns para lidar com restrições é a adoção de uma penalidade na função objetivo. Expandida posteriormente em diversos estudos desde sua proposição, esta abordagem tem como base a ideia de transformar problemas de otimização com restrições em problemas sem restrições, adicionando ou subtraindo um certo valor na função objetivo, o qual é calculado com base na quantidade de restrições violadas de uma determinada solução. Deste modo, a penalização da função objetivo permite resolver problemas com restrições por meio de métodos tradicionalmente propostos para problemas irrestritos.

Segundo COELLO (2002), a função objetivo que penaliza soluções inviáveis, contemplando a penalização para as restrições violadas, pode ser definida como:

$$F(x) = f(x) + p(x), \quad (30)$$

onde $F(x)$ é a nova função objetivo expandida a ser minimizada, $f(x)$ é a função objetivo original e $p(x)$ é a função de penalidade que mensura o grau de violação das restrições intrínsecas ao problema a ser otimizado, que pode ser calculada, segundo CHOOTINAN e CHEN (2006), da seguinte maneira:

$$p(x) = \sum_{j=1}^{n_g} r_j * \max(0, g_j(x) - u_j) - \sum_{j=1}^{n_g} r_j * \min(0, g_j(x) - l_j) + \sum_{k=1}^{n_h} o_k * |h_k(x) - e_k|, \quad (31)$$

sendo r_j e o_k constantes positivas empregadas como fatores de penalização.

Em geral, dados os valores positivos maiores que um para os fatores de penalização, considerando um problema de minimização, a ideia desta abordagem é

penalizar uma solução inviável pelo aumento do *fitness* desta. Logo, diante da característica de cognição social de algoritmos evolutivos, como o PSO, estas soluções tendem a ser descartadas, exprimindo informações que serão úteis durante o processo iterativo do algoritmo e permitindo que novas soluções explorem regiões do espaço de busca potencialmente factíveis.

4.5.1.2 Ajuste pelo Gradiente das Restrições

Apesar de a abordagem baseada em penalização da função objetivo ser conveniente e flexível, o custo computacional para a convergência dos algoritmos que adotam essa estratégia tende a ser elevado, em compasso com a complexidade do modelo e a escala do vetor solução (HUANG *et al.*, 2016). Além disso, dada a característica estocástica das meta-heurísticas, a solução plenamente viável, aquela que respeite todas as restrições, nem sempre poderá ser obtida durante a resolução do problema, uma vez que há grande descarte de informações úteis durante o processo iterativo.

Visando superar estas limitações e potencializar a aplicação dos algoritmos evolutivos nesta classe de problema, CHOOTINAN e CHEN (2006) propõem um método que utiliza a informação de gradiente para corrigir soluções inviáveis. A ideia geral desta abordagem é utilizar as informações derivadas do gradiente do conjunto de restrições a fim de ajustar sistematicamente soluções inviáveis *a priori* para regiões factíveis do espaço de busca. Conforme citam os autores, tal ideia é válida dado que o gradiente pode ser derivado diretamente das restrições das quais existe uma expressão explícita.

$$C = \begin{bmatrix} g_{n_g x_1} \\ h_{n_h x_1} \end{bmatrix}, \quad (32)$$

$$\nabla_x C = \begin{bmatrix} \nabla_x g \\ \nabla_x h \end{bmatrix}_{(n_g+n_h)x_1}. \quad (33)$$

Esta abordagem parte do princípio que, considerando as Equações (32) e (33), C representa a diferença entre o vetor de restrições de desigualdades (g) e igualdades

(h) do problema. Assim, a derivada destas restrições em relação ao vetor solução x (n dimensões – ou variáveis de decisão) é obtida por $\nabla_x C$.

Portanto, a relação entre as mudanças das restrições violadas (ΔC) e o vetor solução corrigido (Δx), bem como o novo valor do vetor solução x' – ajustado em função das restrições violadas – é determinado por:

$$\Delta C = \nabla_x C * \Delta x, \quad (34)$$

$$\Delta x = \nabla_x C^{-1} * \Delta C, \quad (35)$$

$$x' = x + \Delta x. \quad (36)$$

Dadas as expressões acima, os autores afirmam que o inverso da matriz de gradiente ($\nabla_x C^{-1}$) – ou a aproximação equivalente $\nabla_x C^+$ (pseudo-inversa) – fornece uma taxa de reparo do vetor solução x em relação às restrições. Com esta informação, quando o grau de violação da solução x em relação às restrições (ΔC) é conhecido, tal solução pode ser reparada em direção a regiões factíveis, tornando-a viável dentro do espaço de busca do problema. Deste modo, os autores computam o grau de violação das restrições do vetor solução da seguinte forma:

$$\Delta C = \left[\frac{\min\{0, u - g(x)\} + \max\{0, l - g(x)\}}{h(x) - c} \right], \quad (37)$$

onde l e u são vetores de limites mínimos e máximos, respectivamente, para as restrições de desigualdade e c é o vetor de igualdades das restrições h . Os autores ressaltam ainda que não é necessário considerar informações de restrições não violadas. Assim, apenas linhas e colunas de $\nabla_x C$ correspondentes a elementos diferentes de zero em ΔC são consideradas na inversão da matriz de reparo, em $\nabla_x C^{-1}$.

Portanto, para corrigir uma solução inviável, cada variável de decisão do vetor x deve ser ajustada a fim de minimizar a quantidade de restrições violadas. Todavia, o ajuste do vetor solução apresentado na Equação (36) pode não reparar soluções inviáveis de uma vez, dado o número de restrições e a não linearidade destas. Em geral, se propõe a repetição do ajuste até todas as restrições serem respeitadas, o grau de violação ser insignificante ou atingir um número máximo de tentativas (t) de

reparo. Assim, o ajuste pelo gradiente, conforme propõem os autores, pode ser resumido nas seguintes etapas do Pseudocódigo 2.

Pseudocódigo 2: Mecanismo de Ajuste pelo Gradiente das Restrições.

- 1: Definir o número máximo de tentativas de reparo da solução inviável t^{\max} ;
- 2: **Para** cada solução x do enxame **faça**:
 - a. Inicializar controle de tentativas de reparo $t = 0$;
 - b. Determinar o grau de violação das restrições ΔC (Equação (37));
 - c. **Se** a solução for inviável e $t < t^{\max}$ **então**:
 - a) Calcular $\nabla_x C^{-1}$ e Δx (Equações (33) e (35), respectivamente);
 - b) Atualizar o vetor solução x (Equação (36));
 - c) **Se** o vetor atualizado x' é inviável frente as restrições **então**:
 - a. $t = t + 1$;
 - b. Retornar ao Passo 1;
 - d) **Caso contrário**:
 - a. Retornar o vetor de solução x original.

Fonte: Autor.

4.5.2 Viés Estrutural

Segundo PIOTROWSKI e NAPIORKOWSKI (2016), o pleno entendimento do comportamento dos algoritmos de otimização representa um fator chave para o sucesso de suas aplicações, principalmente quando evidencia-se as potenciais limitações que estes oferecem diante das características dos problemas analisados.

Uma potencial deficiência das meta-heurísticas, referida como viés estrutural, é discutida em KONONOVA *et al.* (2015). Segundo os autores, um algoritmo heurístico é estruturalmente tendencioso quando é mais propenso a visitar algumas partes do espaço de busca do que as outras, sendo que este comportamento não é justificado pela função objetivo. Os autores demonstram de forma empírica tal tendência no algoritmo de PSO clássico. Ainda sugerem que o viés estrutural é "mais forte" quando o tamanho da população aumenta e que esse viés tem maior impacto na eficiência de

exploração do espaço de busca de acordo com o nível de dificuldade inerente à resolução do problema.

Outra importante propriedade que contribui para o sucesso do PSO em problemas complexos e de grande porte, segundo KONONOVA *et al.* (2015), é a adoção de uma estratégia eficaz de amostragem de indivíduos que compõem o enxame de partículas, a qual leve em consideração as restrições e a função objetivo do problema. Esta observação vem de encontro com a afirmação de que métodos heurísticos tendem a alcançar soluções ótimas de problemas NP-Difícil quando partem de uma solução viável próxima ao valor ótimo conhecido (GOLDBARG, GOLDBARG e LUNA, 2016).

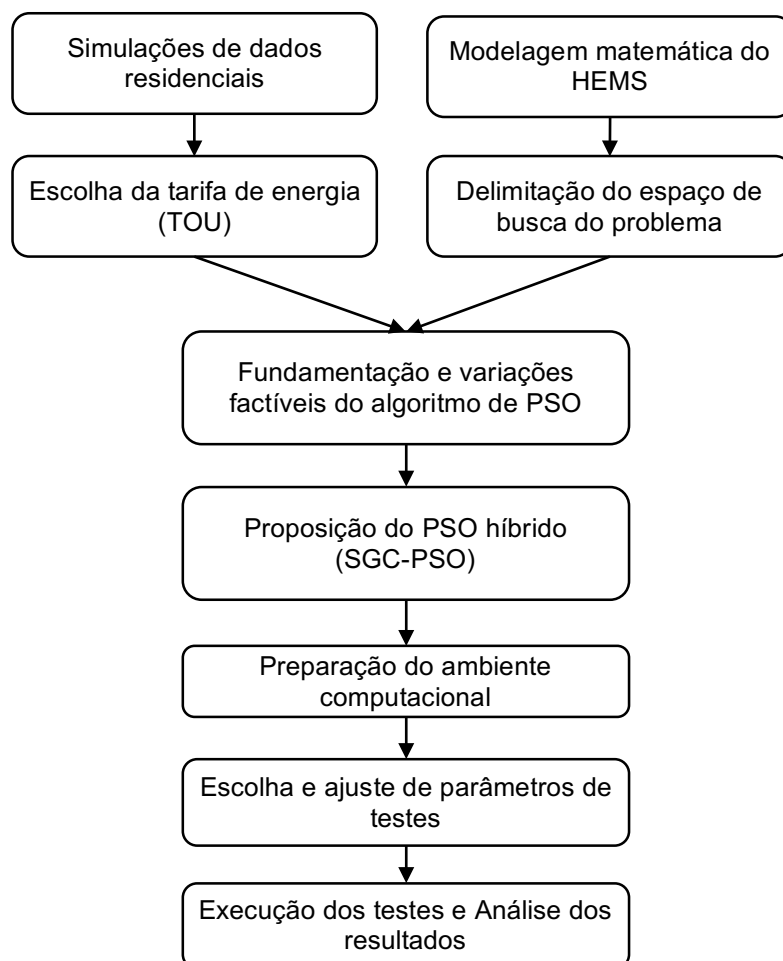
Portanto, diante do contexto supracitado, além das justificativas discutidas nas seções anteriores, a adoção das premissas apresentadas (modelo e método) se mostram coerentes, viabilizando a investigação consequente que será discutida nesta dissertação.

Capítulo 5

METODOLOGIA PROPOSTA

Nesse capítulo serão apresentados os métodos idealizados e desenvolvidos para a resolução do problema de *Demand Response* por meio da implementação do HEMS. Na Figura 10 é exposto o fluxograma que contempla a visão geral da metodologia proposta.

Figura 10: Fluxograma da metodologia adotada.



Fonte: Autor.

5.1 Simulações

Uma premissa fundamental desta dissertação é avaliar a aplicação do PSO em um problema de DR de larga escala, o qual, além de respeitar complexas restrições, lide com o planejamento da operação de um elevado conjunto de aparelhos eletrodomésticos e utilização de bateria para armazenamento de energia, conforme já discutido nas seções anteriores. Logo, é importante informar que as cargas residenciais a serem otimizadas tiveram suas simulações obtidas de SPAVIERI, FERNANDES e VALE (2017). Os autores pontuam que cada carga é considerada independente no modelo adotado, sendo que as restrições de potência e consumo associadas às cargas de cada residência são analisadas isoladamente. Assim, as restrições previamente mencionadas, apresentadas pelas Equações (7), (8) e (10), foram definidas com base na análise dos perfis de consumo simulados pelos autores via o software *Load Profile Generator* (PFLUGRADT, 2016).

Com o intuito de simplificar a aplicação dos métodos propostos no modelo em questão, o conjunto residencial considerado será composto por três residências, sendo todas idênticas. Cada uma destas residências é habitada por 3 moradores, sendo 2 adultos e 1 criança, e contam com 40 cargas cada uma, as quais possuem suas próprias configurações de funcionamento.

A Tabela 6 exibe as cargas, bem como as restrições fixadas para elas. Além disso, as cargas cujo consumo total planejado (E) possui valor igual a zero não são utilizadas pelos consumidores durante o horizonte de planejamento considerado.

Visando representar um microciclo completo do comportamento de consumo residencial, um horizonte de planejamento de 24 horas é assumido no contexto desta pesquisa.

Tabela 6: Parâmetros e restrições associados às cargas da residência.

Cômodo	Descrição	Tipo	γ (W)	α	β	E (kWh)
Banheiro	Lâmpada	1	100	18:00	23:00	0,010
	Lâmpada	1	200	18:00	23:00	0,513
	Secador de cabelo	1	2200	17:00	23:00	0,697
	Chuveiro	1	4500	06:00	23:00	4,500
Quarto	Lâmpada	1	200	18:00	23:00	0,093
	Videogame	2	120	08:00	23:00	0,476
	TV	2	90	08:00	23:00	0,288

Cozinha	Lâmpada	1	200	18:00	23:00	0,383
	Forno Elétrico	1	3600	10:00	20:00	1,200
	Batedeira	1	360	10:00	20:00	0,054
	Cooktop	1	1500	10:00	20:00	1,125
	Micro-ondas	1	2400	06:00	23:00	0,240
	Depurador de ar	1	260	10:00	20:00	0,156
	Rádio-relógio	1	15	10:00	20:00	0,014
	Omeleteira	1	380	06:00	20:00	0,044
	Extrator de Suco	1	290	06:00	20:00	0,058
	Cafeteira	1	1000	06:00	20:00	0,150
	Proc. de Alimentos	1	150	10:00	20:00	0,005
	Torradeira	1	830	06:00	20:00	0,055
	Chaleira	1	1765	06:00	23:00	0,118
	Aparelho de Fondue	2	1620	20:00	23:00	2,565
	Mixer	1	430	10:00	20:00	0,014
Geladeira	3	120	00:00	23:00	2,880	
Sala de estar	Lâmpada	2	100	18:00	23:00	0,320
	Esteira	1	1800	08:00	21:00	4,920
	Aparelho de Som	0	100	10:00	21:00	0
	Computador	1	40	08:00	23:00	0,251
	Monitor	1	23	08:00	23:00	0,070
	Piano Elétrico	2	50	10:00	21:00	0,070
	Videogame	2	18	08:00	23:00	0,027
	TV	1	28	08:00	23:00	0,192
	Notebook	1	42	08:00	23:00	0,070
	Impressora	0	8	08:00	23:00	0
	Copiadora	1	435	08:00	23:00	0,044
	Scanner	1	3	08:00	23:00	0,00005
	Receptor de TV	1	15	08:00	23:00	0,055
	Roteador	3	8	00:00	23:00	0,192
Area de serviço	Aspirador de Pó	1	1400	10:00	21:00	0,513
	Lavadora	0	500	10:00	21:00	0
	Ferro de Passar	1	2400	10:00	21:00	0,520

Fonte: Adaptado de SPAVERI, FERNANDES e VALE (2017).

Nesta tabela, γ representa a potência (em watts) e o intervalo de α a β são os horários de operação factíveis definidos pelos residentes para cada carga. Ainda, o campo *Tipo* é a classificação da carga no que se refere ao seu modo de operação, conforme o modelo matemático apresentado na Seção 4.1.2. Desta forma, são estabelecidas as classificações da Tabela 7.

Tabela 7: Classificação das cargas de acordo com o tipo de operação.

Tipo	Classificação	Otimizado
0	Desligados	Não
1	Interrompíveis	Sim
2	Não-interrompíveis-agendáveis	Sim
3	Ligados durante 24 horas	Não

Fonte: Autor.

A otimização da utilização da bateria, seguindo os preceitos da modelagem matemática descrita na Seção 4.1.2, deve considerar alguns parâmetros e restrições operacionais, conforme mostra a Tabela 8.


Tabela 8: Parâmetros operacionais da bateria residencial.

Parâmetro	Valor	Unidade
$P_{cg}^{max}, P_{d cg}^{max}$	5, 5	kW
$\eta_{cg}, \eta_{d cg}$	0.9, 0.9	%
SOC^{min}, SOC^{max}	0.3, 0.9	p.u.
E_{bat}	8.86	kW

Fonte: Autor.

Por fim, o custo da energia elétrica adotado no processo de otimização de DR segue a tarifação TOU exposta na Figura 11.

Figura 11: Tarifa utilizada no problema de otimização.



Fonte: Adaptado de SPAVIERI, FERNANDES e VALE (2017).

5.2 Abordagem Proposta para Aplicação do PSO

Diante das premissas da modelagem matemática e dos objetivos apresentados na subseção 4.1, levando em consideração a complexidade de problemas de DR intrínsecos em um HEMS, um algoritmo PSO híbrido é proposto a fim de viabilizar a otimização do planejamento da operação de cargas em uma residência. Tal proposta toma como base o trabalho de HUANG, TIAN e WANG (2015) e expande-o em dois sentidos, a saber: (i) amplia o conjunto de aparelhos a terem seu planejamento otimizados pelo algoritmo, simulando os eletrodomésticos presentes em uma residência real, conforme descrito na subseção 5.1; (ii) implementa um mecanismo estocástico para a amostragem de escalonamentos das cargas (variáveis binárias), levando em consideração a tarifa da energia, os tipos de cargas e suas respectivas restrições de operação.

Esta proposta, na qual seu funcionamento pode ser observado na Figura 12, é denominada como SGC-PSO (do inglês, *Stochastic Gradient Correction PSO*). Com base na estrutura geral do algoritmo PSO, esta nova abordagem contempla, além de outros recursos, um mecanismo de correção de soluções inviáveis – considerando os preceitos discutidos nas subseções 4.5.1.2 e 4.5.2 – visando corrigir uma solução

candidata quando esta extrapola as restrições impostas ao problema durante a exploração do espaço de busca.

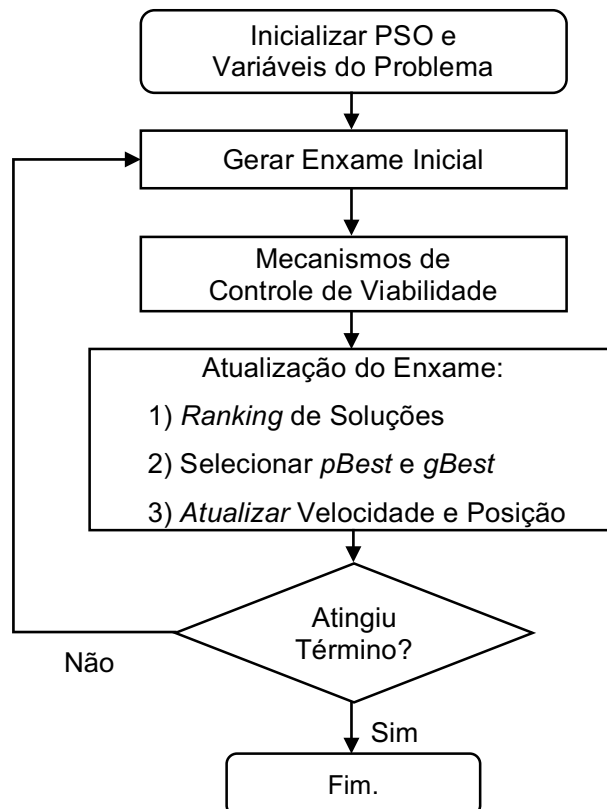
5.2.1 Representação do Indivíduo

Para a representação dos indivíduos do enxame, foi considerado um espaço de busca híbrido, uma vez que contempla dimensões reais e binárias, possuindo a seguinte estrutura:

$$x = \left[x_{bat(1x48)} \ x_{car(1x960)} \right]_{(1x1008)} \quad (38)$$

As dimensões reais (x_{bat}) representam a quantidade de carga ou descarga (em kWh) da bateria na hora h do horizonte de planejamento diário. As dimensões binárias (x_{car}) representam o estado dos eletrodomésticos em cada hora do dia, sendo que 0 representa que a carga está desligada e 1 representa que a carga está em operação.

Figura 12: Fluxograma da abordagem SGC-PSO proposta.



Fonte: Autor.

Sendo assim, um vetor solução x do PSO possui dimensão $d = (24 + 24) + (40 * 24) = 1.008$. Deste modo, é possível notar um problema de larga escala, justificando-se a necessidade de adoção de estratégias que viabilizem a aplicação deste algoritmo no problema estudado. Ao final, o algoritmo retorna o vetor de utilização da bateria e a matriz de planejamento da operação das cargas que apresentaram melhores resultados na minimização da função de *fitness*, estabelecida na Equação (1).

Logo, o SGC-PSO possui uma característica híbrida, pois para as variáveis reais a atualização seguirá as regras descritas nas Equações (20) a (22). Por outro lado, para as variáveis binárias, a atualização da posição será regida pelo BPSO, considerando as Equações (24) e (25). A geração inicial do enxame é concebida de forma aleatória, considerando as particularidades dimensionais aqui discutidas.

5.2.2 Mecanismos de Controle de Viabilidade

Dada a característica estocástica do PSO, sua proposição original contemplava aplicações eficientes em problemas irrestritos, o qual permitia a exploração total do espaço de busca sem limitações. Contudo, problemas do mundo real, especialmente no domínio de otimização do setor energético, possuem restrições que devem ser obrigatoriamente respeitadas para uma solução poder ser considerada viável.

No contexto desta dissertação, por exemplo, a utilização da bateria de armazenamento de energia deve considerar fatores de sustentabilidade de sua vida útil, e aparelhos eletrodomésticos devem respeitar premissas de usabilidade definidas pelos residentes. Portanto, o sucesso da aplicação algoritmo PSO na implementação de HEMS está alinhado ao desenvolvimento de estratégias que mitiguem problemas relacionados a viabilidade de soluções presentes no enxame a fim de guiar os indivíduos em uma exploração eficiente do espaço de busca.

5.2.2.1 Utilização da Bateria


No que diz respeito às restrições de utilização da bateria de armazenamento de energia elétrica descritas na modelagem do problema, o SGC-PSO conta com um mecanismo de correção pelo gradiente das restrições de carga, tornando uma solução

que seria inviável em uma solução que atenda as restrições impostas a este equipamento.

A Figura 13 elucida intuitivamente o funcionamento do mecanismo de correção pelo gradiente quando aplicado em um problema bidimensional. Neste problema, uma solução inicialmente inviável é conduzida iterativamente até uma região factível no domínio do problema. Isso é feito por meio de pequenos ajustes derivados do gradiente em relação à solução atual, conforme detalhado na subseção 4.5.1.2.

Deste modo, no contexto desta dissertação e da abordagem proposta no SGC-PSO, o vetor de solução parcial x_{bat} é validado pelo mecanismo de correção pelo gradiente no momento de inicialização do enxame e durante as iterações do PSO. Assim, busca-se corrigir tal solução, a qual pode originar uma nova amostragem que respeita as restrições impostas para a utilização sustentável da bateria, potencializando a exploração do espaço de busca factível.

Figura 13: Mecanismo de correção pelo gradiente aplicado em um problema bidimensional.



Fonte: Adaptado de CHOOTINAN e CHEN (2006).

5.2.2.2 Agendamentos Estocásticos dos Equipamento Eletrodomésticos

Diante dos preceitos discutidos, o vetor binário x_{car} apresenta um desafio para a eficiente implementação do algoritmo PSO no problema discutido, uma vez que este representa o planejamento diário de cada equipamento presente na residência, ou seja, para cada novo equipamento considerado na otimização, 24 novas dimensões devem ser adicionadas a este vetor. Logo, problemas de otimização de DR do mundo real apresentam elevada complexidade e larga escala. Conforme discutido na subseção 4.5.2, estas características levam à necessidade de desenvolver estratégias eficientes para amostragem de indivíduos a fim de mitigar o problema de viés estrutural.

Além disso, com base na função objetivo, disposta na Equação (1), pode-se afirmar que o valor da energia na função $TOU(h)$ representa um relevante fator de concentração de demanda, uma vez que o vetor de planejamento da operação x_{car} otimizado deve evitar acionar as cargas em momentos que a energia apresente maior custo. Tal comportamento, além de potencializar a redução do custo atrelado ao consumo da energia elétrica para os consumidores, ainda cumpre aos objetivos da concessionária ao implementar programas de DR.

Diante destas premissas, o Pseudocódigo (2) apresenta o algoritmo que projeta o mecanismo proposto para a amostragem estocástica do planejamento da operação das cargas.

Pseudocódigo 2: Mecanismo de agendamento estocástico.

Considerando as restrições de operação de carga – Equações (10) a (15).

- 1: Extrair horários de pico de custo da energia \mathcal{P} , baseado em $TOU(h)$;
 - 2: **Para** cada carga a **faça**
 - a. Inicializar x_{car}^a como um vetor de zeros de dimensão (1×24) ;
 - b. Calcular duração λ de operação da carga, considerando E ;
 - c. Definir o intervalo de horários da janela de operação $\mathcal{H} \in [\alpha \beta]$;
 - d. Criar vetor auxiliar δ , onde cada δ_i representada a probabilidade do horário $h \in$ alocar parte carga da carga de E , contendo iguais probabilidades neste momento;
-

-
- e. Para cada $\rho_i \in \mathcal{P}$, penalizar em 90% o valor δ_i , diminuindo a probabilidade de \mathcal{H}_i ser utilizado no planejamento;
 - f. Reequilibrar vetor δ , potencializando horários fora de pico, tal que seja respeitada a propriedade probabilística $\sum \delta_i = 1$;
 - g. Definir estocasticamente os horários \mathcal{E} que irão operar a carga E , levando em consideração δ e λ ;
 - h. Acionar a operação do horário $e_i \in \mathcal{E}$ no vetor x_{car}^a ;
 - i. Atualizar o vetor $x_{car} = [x_{car} \ x_{car}^a]$.
-

Fonte: Autor.

5.2.3 Atualização do Enxame

A proposta do SGC-PSO leva em consideração as equações de atualização do enxame dispostas no PSO com Fator de Construção (apresentado na subseção 4.4.3), tratando as dimensões reais e binárias conforme explicado anteriormente. Cabe ressaltar ainda que, conforme destaca VALLE *et al.* (2008), a atualização de velocidade durante as iterações do PSO pode representar também um fator importante para a eficiente aplicação do algoritmo quando este é aplicado em um problema de alta complexidade. Logo, a limitação da velocidade máxima do enxame evita que a diversidade de exploração do espaço seja elevada, a qual pode comprometer a convergência desta meta-heurística (GOLDBARG, GOLDBARG e LUNA, 2016). Portanto, seguindo os trabalhos anteriores, bem como ZOBBA e VACCARO (2015), adota-se na abordagem proposta a seguinte estratégia de controle de velocidade:

$$V_i^{max} = X_i^{max} - X_i^{min}, \quad (39)$$

$$V_i^t = \begin{cases} V_i^{max}, & V_i^t > V_i^{max} \\ -V_i^{max}, & V_i^t < -V_i^{max} \\ V_i^t, & \text{caso contrário} \end{cases}, \quad (40)$$

onde a i -ésima dimensão de velocidade está restrita a velocidades mínima ($-V_i^{max}$ e máxima V_i^{max}), permitindo que o enxame vasculhe de modo mais minucioso o complexo espaço de busca.

5.2.3.1 Ranking de Soluções

Em problemas de otimização clássicos, a escolha dos melhores indivíduos de um enxame é feita pelo valor da função objetivo calculada para cada solução candidata. Todavia, em problemas que contemplem restrições ao modelo matemático, as melhores soluções devem avaliar o grau de viabilidade, além de seu *fitness* em si, pois a eficiência de uma solução frente ao problema deve equalizar estas duas métricas, ao passo que se maximize o atendimento às restrições impostas e minimize o *fitness* estabelecido. Neste sentido, DONG *et al.* (2005) propõem um método de avaliação de partículas baseado no balanço destes dois objetivos, o qual denominam por *Ranking de Fitness e Atendimento às Restrições*.

$$F(x) = [f(x) \ v(x)], \quad (41)$$

$$v(x) = \sum_{j=1}^r w_j * \zeta_j(x), \quad \sum_{j=1}^r w_j = 1, \quad 0 \leq w_j \leq 1, \quad \forall j \quad (42)$$

Neste *Ranking*, as soluções do enxame são classificadas de acordo com a nova função $F(x)$, que contempla os valores da função de viabilidade $v(x)$ e da função *fitness* $f(x)$ do problema. Na Equação (42), r é o conjunto contendo o intervalo de índices com base no total de restrições de desigualdade (n_g) e igualdade (n_h) presentes na modelagem, w_j é um fator inserido para dar caráter estocástico ao cálculo e $\zeta_j(x)$ é a função que calcula o grau de viabilidade da solução x no que diz respeito à j -ésima restrição do problema.

Para restrições de desigualdade $g(x)$, o cálculo de $\zeta_j(x)$ se faz da seguinte forma:

$$\zeta_j(x) = \begin{cases} 1, & l \leq g_j(x) \leq u \\ 1 - \frac{|g_j(x)|}{|g_{max}(x)|}, & l > g_j(x) > u' \end{cases} \quad (43)$$

onde $g_{max}(x) = \max\{g_j(x) \mid j = 1, 2, \dots, n_g\}$. Já para restrições de desigualdade, calcula-se o grau de viabilidade conforme:

$$\zeta_j(x) = \begin{cases} 1, & h_j(x) = c \\ 1 - \frac{|h_j(x)|}{|h_{max}(x)|}, & h_j(x) \neq c' \end{cases} \quad (44)$$

tal que $h_{max}(x) = \max\{h_j(x) \mid j = 1, 2, \dots, n_h\}$. Deste modo, conforme demonstrado nas Equações (42) a (44), o valor calculado em $v(x)$ representa o nível de aptidão da solução x em relação ao conjunto de restrições do problema. Se $\zeta_j(x) = 1$, então x é uma solução factível. Caso contrário, se $0 \leq \zeta_j(x) < 1$, quanto mais próximo de zero, menos factível é x para a resolução do problema, uma vez que evidencia menor grau de viabilidade da solução x frente às restrições do problema.

Com base no comportamento canônico do PSO, que estabelece que cada partícula voa sempre pelo espaço de busca do problema seguindo uma solução ideal atual com o melhor *fitness*, a ideia básica para implementar a seleção das melhores soluções pelo *Ranking de Fitness e Atendimento às Restrições* pode ser descrita da seguinte forma: (i) todas as partículas são submetidas à função $F(x)$ e classificadas de acordo com o seu valor de *fitness* $f(x)$, conforme Equação (40); (ii) o enxame é ordenado pelo grau de viabilidade, segundo termo de $F(x)$, de modo decrescente; (iii) se duas ou mais soluções tiverem o mesmo valor de $v(x)$, seus valores de $f(x)$ são comparados; (iv) a solução com melhor valor de *fitness* terá prioridade.

Adotando esta estratégia, DONG *et al.* (2005) afirmam que o PSO explora de modo mais eficiente o espaço de busca, uma vez que, baseado na operação evolutiva, a melhor solução possível atual é obtida a partir de partículas (soluções) viáveis melhores que a geração anterior. Outra vantagem do método é que não há necessidade de ajustar fator ponderado entre funções de *fitness* e grau de viabilidade, facilitando a aplicação em problemas do mundo real.

A partir dessa discussão, sabe-se que há dois níveis de competição no algoritmo. Uma é a competição de sobrevivência dentro das restrições. O melhor indivíduo sobrevive em todas as gerações. O outro é a competição entre restrições e *fitness*. De acordo com os valores de $f(x)$ e $v(x)$ englobados em $F(x)$, todas as soluções do enxame são classificadas levando em consideração estas duas métricas. A melhor partícula estará na primeira posição do *Ranking*, enquanto a pior na posição final. O valor da função de *fitness* da primeira posição é atualizado continuamente. Como resultado, a solução otimizada ideal se aproxima rapidamente durante a evolução do PSO.

Portanto, o SGC-PSO utiliza o *Ranking* proposto para avaliar os indivíduos e selecionar as melhores soluções $pBest$ e $gBest$ a cada iteração do algoritmo.

5.2.4 Critérios de Parada

O algoritmo SGC-PSO tem sua execução encerrada quando exceder um número máximo de gerações definidos *a priori* ou quando uma melhor solução que a atual não é obtida após um certo número de iterações.

5.3 Estudo de caso

Visando avaliar a eficácia da proposta na resolução do problema de DR de larga-escala, serão feitas análises dos resultados obtidos pelo SGC-PSO, bem como realizadas comparações quantitativas frente às soluções obtidas por variações do algoritmo PN-PSO, seguindo as discussões apresentadas nos capítulos anteriores. Ainda, a proposta é comparada com a solução obtida pelo pacote de solução exata CPLEX, a fim de mensurar sua eficiência de modo mais assertivo.

Os algoritmos de otimização por enxames de partículas foram implementados utilizando a ferramenta MATLAB. Já o método exato baseado no CPLEX foi implementado utilizando o software AMPL. Todos os testes foram executados no sistema operacional OSX El Captain 10.11.6, em um computador com processador de 2.26GHz Intel Core 2 Duo, memória RAM de 8gb 1067MHz DDR3 e placa de vídeo NVIDIA GeForce 9400 256MB e 1Tb de HD.

Os algoritmos de PSO considerados neste trabalho foram testados individualmente 50 vezes, e as configurações gerais de parâmetros de cada algoritmo implementado foram estabelecidos conforme disposto na Tabela 9. Vale ressaltar que cada algoritmo aqui descrito foi também submetido a variações no modo de calcular as equações de velocidade, as quais foram discutidas nas subseções 4.4.1, 4.4.2 e 4.4.3.

Tabela 9: Configurações dos PSOs analisados.

Parâmetro	SGC-PSO	PN-PSO
População	50	50
Iterações	1.000	1.000
Limite de Estagnação	100	100
φ_1 / φ_2	<i>Real: (2.05 / 2.05) , Binário: (2 / 2)</i>	2.05 / 2.05

Fonte: Autor.

Capítulo 6

RESULTADOS

Com base no modelo matemático apresentado, este trabalho visa conduzir uma comparação efetiva acerca do desempenho da proposta de SGC-PSO frente aos algoritmos de PSO dispostos na subseção 4.4, bem como do método exato implementado no *solver* CPLEX, de modo a fornecer indicadores relevantes sobre as particularidades e desempenho desta abordagem quando aplicada à solução de problemas de *Demand Response* baseados no preço da energia.

Mais especificamente, o problema de DR aqui apresentado consiste na resolução de DSM para uma residência, considerando a produção e armazenamento de energia.

6.1 Comparação com o CPLEX

Conforme HUANG, TIAN e WANG (2015), muitos métodos comerciais de solução exata, como o CPLEX, foram aplicados na resolução de problemas de otimização complexos. Tais métodos oferecem uma boa métrica comparativa, uma vez que possuem grande capacidade de obter resultados ótimos, quando aplicados em modelos matemáticos que lhe são pertinentes. Ao mesmo tempo, estes métodos demandam grande capacidade de processamento, o que limita sua implementação em dispositivos embarcados, como o ECS (do inglês, *Energy Consumption Scheduler*), utilizado por executar o algoritmo de otimização e controlar a operação das cargas na residência. Neste sentido, torna-se conveniente avaliar o desempenho

do SGC-PSO frente ao CPLEX, dado que métodos meta-heurísticos possuem facilidade de implementação em dispositivos com recursos computacionais limitados.

Tendo em vista a validação da assertividade da abordagem proposta no SGC-PSO com base na metodologia adotada pelos autores supracitados, um cenário de simulação em pequena escala foi estabelecido para realizar a comparação com a solução obtida pelo *solver* CPLEX, contemplando, a partir do modelo descrito nesta dissertação, a otimização da operação das cargas de uma residência que conta com dois aparelhos eletrodomésticos (especificados na Tabela 10) e uma bateria residencial (Tabela 8), além de uma tarifa de energia baseada no modelo TOU (Figura 11).

Tabela 10: Cenário residencial da comparação SGC-PSO versus CPLEX.

Descrição	Tipo	γ (W)	α	β	E (kWh)
Aparelho X	1	1500	9	24	4,5
Aparelho Y	2	1000	12	22	4,5

Fonte: Autor.

Tanto o CPLEX como o SGC-PSO foram submetidos a 50 execuções cada um. Seus desempenhos são sumarizados na Tabela 11. Conforme se observa, do mesmo modo que o CPLEX, o SGC-PSO possui grande habilidade de lidar com as restrições do problema, sendo capaz de localizar uma solução factível em um curto espaço de tempo. Em média, as soluções resultantes do SGC-PSO são equivalentes às oriundas do CPLEX, ao mesmo tempo que a obtenção de uma solução factível às restrições do problema de baixo custo é realizada em tempo computacional viável pela abordagem proposta. Ainda, o melhor resultado encontrado pelo SGC-PSO é ligeiramente menor em relação ao obtido pelo CPLEX, denotando assim que a exploração do espaço de busca do problema, conduzida pela abordagem proposta, é mais profunda e detalhada.

Portanto, de acordo com os resultados aqui apresentados, o SGC-PSO se coloca como uma alternativa viável para o problema de DR, uma vez que apresenta efetiva convergência, grande capacidade de lidar com restrições complexas (discretas e não lineares) e seu algoritmo pode ser facilmente implementado em arquiteturas embarcadas, como a do ECS.

Tabela 11: Resumo comparativo entre SGC-PSO e CPLEX.

Método	Melhor Resultado	Resultado Médio	Solução Factível (médio)	
			<i>Fitness</i>	Tempo de CPU (s)
CPLEX	1,13	1,13	1,13	1,20
SGC-PSO	0,64	1,14	2,26	1,51

Fonte: Autor.

6.2 Comparação com o PN-PSO

Uma alternativa para realizar a aplicação do algoritmo PSO em problemas complexos é o PN-PSO, que se mostra como uma abordagem eficiente para tarefas de otimização com restrições, conforme mostrado na subseção 4.5.1.1. Assim, comparar o desempenho do SGC-PSO proposto em relação ao PN-PSO no modelo matemático desta dissertação pode corroborar com a hipótese de que a abordagem baseada no gradiente das restrições e amostragem estocástica de agendamento é eficiente na resolução do problema de DR.

Neste contexto, foram realizados 50 testes individuais comparando estes dois métodos meta-heurísticos. A otimização foi realizada considerando um perfil residencial próximo à realidade (larga escala), onde as cargas, limitações de uso da bateria e demais variáveis foram descritas na seção 5.1.

Todavia, o indicador comparativo entre os dois algoritmos deve ser tratado isoladamente, uma vez que o PN-PSO possui um acréscimo na função de aptidão para cada restrição violada, diferentemente do SGC-PSO, que possui um *fitness* conforme descrito na Equação (1). Para cada restrição violada no PN-PSO, o *fitness* sofre um acréscimo de 100 unidades. Deste modo, para realizar a comparação acerca do *fitness* entre ambas as abordagens aqui discutidas, os resultados desta abordagem sofrem um decréscimo referente ao somatório das restrições violadas.

Conforme pode ser observado na Tabela 12, o SGC-PSO possui desempenho consideravelmente superior ao PN-PSO no problema de otimização de DR tratado nesta dissertação. Considerando o menor *fitness*, ou seja, a melhor solução obtida pelos dois métodos, a abordagem aqui proposta é quase 10 vezes superior ao PSO

com penalidade da função objetivo. Ainda, diante dos testes realizados, constatou-se que o SGC-PSO possui grande eficiência em seu propósito de otimização, uma vez que possui um desvio padrão baixo quando comparado ao método concorrente. Tal comportamento fica evidente quando se observa a diferença entre os valores mínimos e máximos obtidos. Por fim, os percentis estatísticos corroboram com a integridade da eficácia do SGC-PSO na resolução do problema discutido, pois além do baixo *fitness*, que representa o menor custo para o consumidor final, há-se ainda uma baixa volatilidade entre os quartis.

Tabela 12: Resumo de desempenhos do SGC-PSO e PN-PSO.

Método	Mínimo	Máximo	Médio	Desvio Padrão	Percentil (%)		
					25	50	75
SGC-PSO	10,32	11,72	10,51	0,33	10,35	10,39	10,46
PN-PSO	97,17	132,52	116,80	8,50	111,96	116,17	122,73

Fonte: Autor.

Considerando apenas as melhores soluções (*fitness* sem acréscimo de penalidade) obtidas pelos métodos, percebe-se pela Tabela 13 que o PN-PSO possui grande dificuldade de convergência, dada a complexidade das restrições do problema de DR dispostas no modelo matemático. Tal característica fica evidente quando se compara o grau de viabilidade (SGC-PSO) / penalidade (PN-PSO) nos dois casos. Enquanto a abordagem proposta atinge de maneira eficiente uma solução factível, potencializando a convergência do PSO na exploração do espaço de busca, o PN-PSO sofre com as restrições da modelagem, explorando de modo ineficiente o domínio do problema e, conseqüentemente, levando a uma solução de alto custo no que se refere à função objetivo.

De acordo com essa afirmação e considerando o agendamento oriundo da melhor solução obtida pelo PN-PSO exposto na Figura 14, é possível observar, por exemplo, que a operação sugerida para o videogame (destacado no retângulo vermelho) extrapola as restrições do problema de duas formas: (i) o intervalo definido pelo residente para o escalonamento do aparelho (retângulo azul) não é respeitado, uma vez que visivelmente há o acionamento da carga (quadrado preto) em momentos

inoportunos, não assegurando a premissa de utilização do mesmo; e (ii), o modo de operação (não-interrompível) da carga não é respeitado no agendamento resultante.


Tabela 13: Melhores soluções obtidas pelo SGC-PSO e PN-PSO.

Método	<i>Fitness</i> (Sem Acréscimo*)	<i>Fitness</i> (Original)	Grau de Viabilidade / Penalidade	Factível (Restrições)
SGC-PSO	10,32	10,32	1	SIM
PN-PSO*	97,17	20.297,17	20200	NÃO

Fonte: Autor.

Portanto, considerando um cenário complexo e de larga escala, o mecanismo de correção pelo gradiente e amostragem estocástica proposto no SGC-PSO se mostra extremamente eficaz para a convergência deste algoritmo em problemas de DR, principalmente quando comparado a abordagens convencionais do PSO para aplicação em problemas que contemplem restrições, como o aqui discutido. Este resultado corrobora KONONOVA et al. (2015) e também com as características dos mecanismos para lidar com as restrições propostos no SGC-PSO, dado que o algoritmo de PSO se mostra suscetível a possuir viés estrutural, necessitando de estratégias que mitiguem tal efeito indesejado, principalmente no caso do problema de DR, onde o *fitness* tem forte correlação com uma função externa à função de aptidão (neste caso, a função de tarifação da energia elétrica).

Figura 14: Agendamento de cargas da melhor solução obtida pelo PN-PSO.



Fonte: Autor.

6.3 Variações no Modo Atualização do Enxame no SGC-PSO

Diante da eficiência destacada até aqui, a exploração de ajustes adicionais do SGC-PSO se mostra coerente. Diversos estudos apontam que um dos ajustes mais significativos dos algoritmos PSO é a escolha das equações de atualização do enxame, pois suas variações podem representar comportamentos individuais distintos na exploração do espaço de busca, de modo que a escolha adequada do modo de atualização pode ter impacto relevante na convergência do algoritmo (SHI e EBERHART, 1999; GOLDBARG, GOLDBARG e LUNA, 2016).

Justifica-se, portanto, analisar diferentes modos de atualização do enxame existentes na literatura a fim de validar a melhor estratégia a ser adotada neste quesito para o algoritmo SGC-PSO. Assim, quatro modos de atualização distintos foram testados na resolução do problema de DSM aqui descrito, sendo eles: modo canônico (CAN), decréscimo linear da inércia (DCL), inércia individualizada e adaptativa (ADP)

e fator de constrição (FTC), os quais foram descritos nas subseções 4.4.1 a 4.4.5, respectivamente. Em tempo, ressalta-se que o cenário de testes considerado na otimização segue o mesmo do apresentado na Seção 6.2.

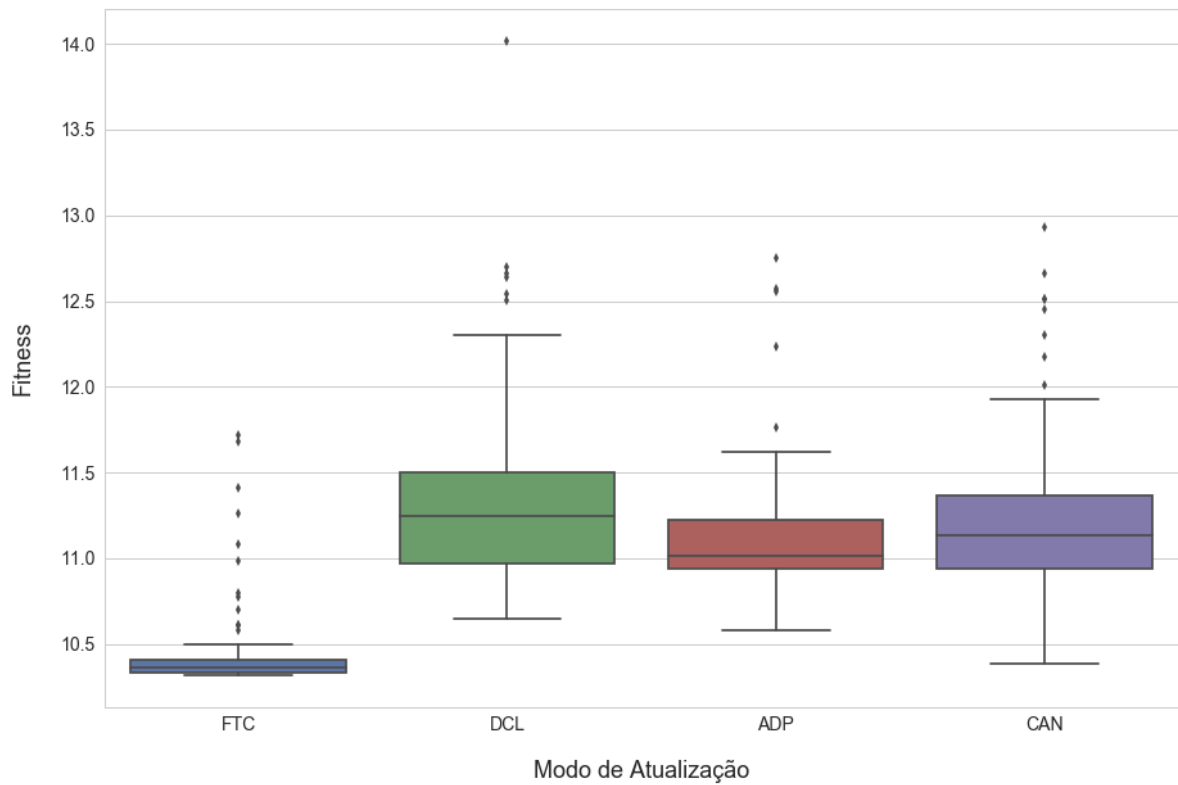
Percebe-se pela Tabela 14 que o SGC-PSO implementado com FTC, como estabelecido *a priori*, apresenta o melhor resultado, tanto para o menor *fitness* quanto para o menor desvio padrão dentro dos 50 testes conduzidos para cada modo de atualização avaliado.

Tabela 14: Resultados para cada modo de atualização do SGC-PSO.

Modo	Fitness				Percentil (%)		
	Mínimo	Máximo	Médio	Desvio Padrão	25	50	75
CAN	10,38	12,93	11,29	0,60	10,94	11,14	11,36
DCL	10,65	14,02	11,41	0,66	10,97	11,25	11,50
ADP	10,58	12,75	11,15	0,46	10,94	11,01	11,22
FTC	10,32	11,72	10,51	0,33	10,35	10,39	10,46

Fonte: Autor.

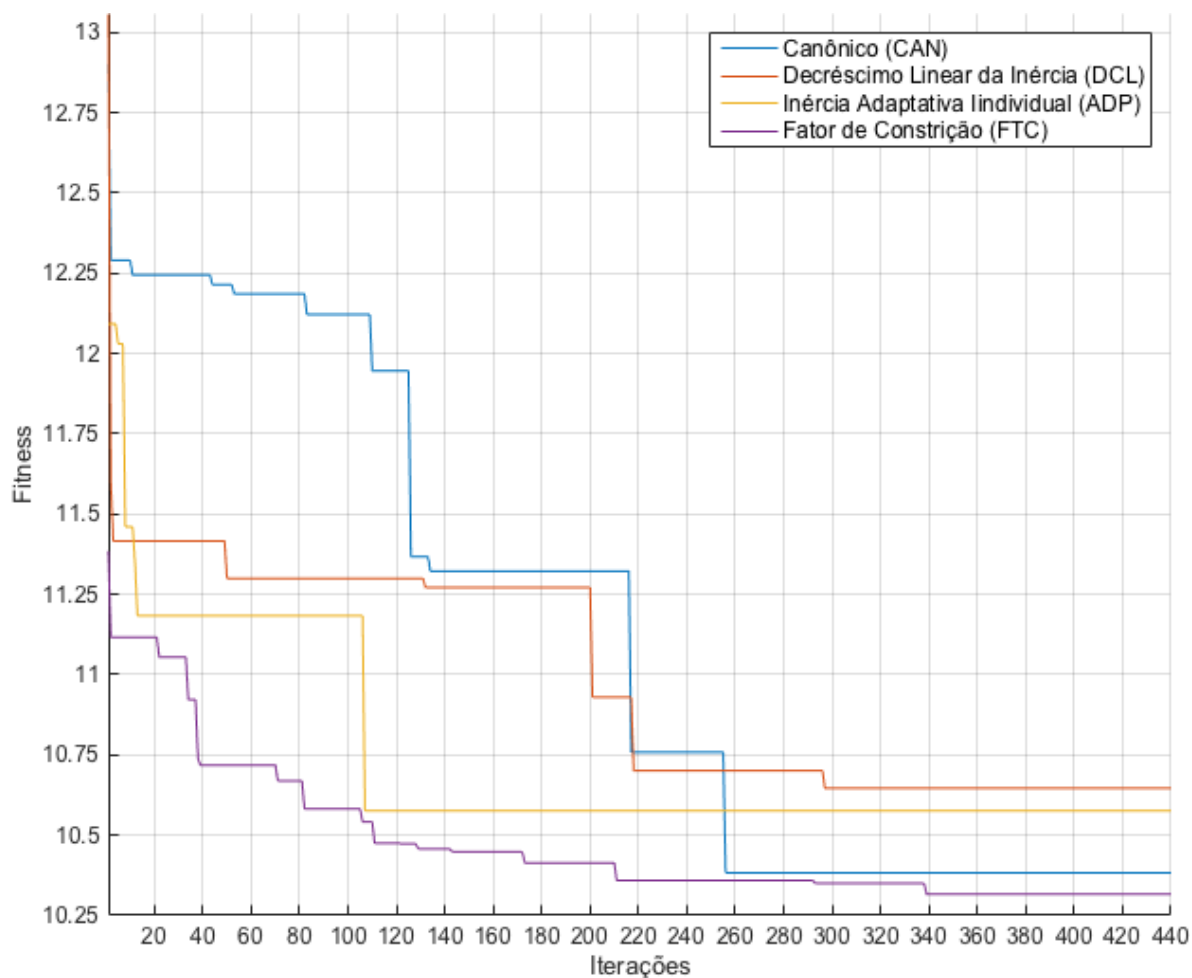
É possível afirmar, conforme exibe a Figura 15, que o método ADP também se coloca como uma alternativa ao FTC para guiar os indivíduos no espaço de busca explorado pelo SGC-PSO, uma vez que apresenta um comportamento coeso de convergência e considerável eficácia na minimização da função objetivo. Ainda neste gráfico, é possível observar que, apesar de atingir o segundo menor *fitness*, a atualização do exame pelas equações canônicas (CAN) apresenta evidente instabilidade na convergência do algoritmo, característica esta expressa por meio de elevado desvio padrão. Por fim, dentre os modos de atualização analisados, o DCL evidencia-se como a escolha menos favorável para aplicação no problema de DSM, sendo que este apresenta, além de largo desvio padrão frente às outras alternativas, o pior resultado de todo o conjunto de testes obtidos.

Figura 15: Dispersão dos Resultados dos Diferentes Modos de Atualização.

Fonte: Autor.

Por fim, a Figura 16 exibe o gráfico de convergência das melhores soluções obtidas pelos quatro modos de atualização do enxame. Observa-se que, principalmente, as equações do FTC auxiliam efetivamente o PSO, permitindo uma rápida e contínua convergência do algoritmo em busca da melhor solução.

Figura 16: Convergência das Melhores Soluções de cada Modo de Atualização.



Fonte: Autor.


Por outro lado, o modo de atualização canônico (CAN), apesar de chegar a uma solução de baixo custo, apresenta minimizações esporádicas da função objetivo. Ainda que este não seja um problema tão relevante, dada a análise de dispersão de resultados anteriores (Tabela 14 e Figura 15), é possível observar que o FTC é amplamente mais estável no seu processo de varredura do espaço de busca viável do problema, sendo sua adoção, portanto, tida como inerente à implementação do SGC-PSO proposto nesta dissertação.

6.4 Análises Adicionais do SGC-PSO

A fim de mensurar a real eficiência e aderência do SGC-PSO no contexto prático, de modo que o usuário final tome ciência dos benefícios em sua adoção, alguns indicadores econômicos podem ser derivados a partir da melhor solução obtida pela abordagem proposta.

A Figura 17 mostra o planejamento resultante da melhor solução obtida pelo SGC-PSO para a utilização das cargas residenciais. As linhas vermelhas pontilhadas delimitam o horário de pico de tarifa da energia elétrica; o valor positivo da bateria se refere à compra de energia da rede para armazenamento e o valor negativo exprime a venda de energia armazenada para a rede. Deste modo, fica evidente que o algoritmo busca otimizar o escalonamento de operação dos aparelhos elétricos e utilização da bateria em função da variação tarifária, com o intuito de reduzir a conta de energia, respeitando as premissas de utilização definidas pelos consumidores.

Figura 17: Planejamento de Cargas Otimizado para Residência.




Fonte: Autor.

Além de encontrar o melhor horário de acionamento, percebe-se que o SGC-PSO busca comprar energia em momentos de tarifas baixas e vender energia excedente em momentos de pico, buscando equilibrar os benefícios do modelo

tarifário TOU implementado no programa de DR baseado em tarifas. Este comportamento está alinhado tanto às expectativas dos consumidores quanto da concessionária, dado que a implementação de tarifação diferenciada visa oferecer incentivos financeiros a fim de minimizar o consumo em horários que podem comprometer o sistema de energia.

Com um consumo de R\$ -2,20 kW médio por hora durante o horário de pico, frente a 1,27 kW médio consumido por hora dentro do horizonte de planejamento, o algoritmo expõe sua capacidade em utilizar toda a informação disponível para minimizar o consumo de energia. A variação tarifária resultante pode ser observada na Figura 18. Em tempo, vale ressaltar que os períodos que compreendem maiores consumos de energia respeitam as restrições da janela de funcionamento impostas pelo consumidor para a operação de cada aparelho.

Figura 18: Variação Tarifária do Planejamento Otimizado.




Fonte: Autor.

Por fim, o planejamento otimizado de operação das cargas, além de viabilizar o conhecimento dos residentes acerca do agendamento proposto pelo algoritmo, servirá de insumo para a execução do dispositivo ECS – acionando ou desligando os equipamentos domésticos. Tal planejamento pode ser visto na Figura 19, onde cada linha representa uma das cargas presentes na residência e cada coluna representa

uma unidade horária. Logo, cada retângulo preto representa o acionamento da carga em uma determinada hora do dia.

Portanto, nota-se pelos resultados os preceitos discutidos, corroborando a tendência de gestão otimizada e eficiente de cargas do SGC-PSO, que minimiza o valor total gasto com energia elétrica diante das variações de preço da energia, considerando a presença de dispositivos de armazenamento de energia, fonte de energia renovável e respeita as restrições de utilização dos aparelhos residenciais.

Figura 19: Agendamento de Carga Otimizado Proposto pelo SGC-PSO.



Fonte: Autor.

Capítulo 7

CONSIDERAÇÕES FINAIS

Considerando um modelo robusto do problema de DSM, os resultados mostram que o mecanismo proposto para lidar com as restrições contribui de maneira efetiva para a aplicação do PSO em um cenário residencial de larga escala, de modo que, além de mostrar-se equivalente ao método exato CPLEX, melhora significativamente seu desempenho frente a alternativas convencionais deste algoritmo no contexto dos testes conduzidos neste trabalho. Ainda, tal resultado viabiliza a implementação do SGC-PSO em dispositivos embarcados como o ECS.

Portanto, a abordagem de PSO aqui apresentada é eficiente em gerenciar o consumo de energia elétrica por meio do planejamento de operação de cargas em uma residência, minimizando os custos dos consumidores frente às variações tarifárias ao mesmo tempo que reduz a utilização de um conjunto de cargas em horários de pico. Vale ressaltar que estes objetivos são atingidos levando em consideração um cenário de otimização extremamente complexo, contemplando a utilização sustentável de bateria, distintos modos de operação dos aparelhos elétricos, além do comportamento e as preferências do consumidor, características estas de suma importância para a aderência de um programa que visa o gerenciamento pelo lado da demanda.

Para a evolução do estudo, a integração de um módulo de previsão de produção de energia fotovoltaica ao SGC-PSO, levando em consideração fatores climáticos e operacionais, bem como a definição de novos perfis residenciais (com base em características regionais brasileiras) e o desenvolvimento de mecanismos para lidar com o conforto dos consumidores, podem potencializar sua implementação em cenários reais de *Smart Grids*.

REFERÊNCIAS

ABEDIN, Z. U.; SHAHID, U.; MAHMOOD, A.; QASIM, U.; KHAN, Z. A.; JAVAID, N. Application of PSO for HEMS and ED in Smart Grid. **Proceedings - 2015 9th International Conference on Complex, Intelligent, and Software Intensive Systems, CISIS 2015**, p. 260–266, 2015.

AGHAEI, J.; ALIZADEH, M.-I. Demand response in smart electricity grids equipped with renewable energy sources: A review. **Renewable and Sustainable Energy Reviews**, v. 18, p. 64–72, 2013.

ALBADI, M. H.; EL-SAADANY, E. F. Demand Response in Electricity Markets. **IEEE - Power Engineering Society General Meeting**, p. 1–5, 2007.

ALBERINI, A.; FILIPPINI, M. Response of residential electricity demand to price: The effect of measurement error. **Energy Economics**, v. 33, n. 5, p. 889–895, 2011.

ARIA, M.; CUCCURULLO, C. bibliometrix: A R tool for comprehensive bibliometric analysis of scientific literature. <http://www.bibliometrix.org>, 2016.

BARBATO, A.; CAPONE, A. Optimization models and methods for demand-side management of residential users: A survey. **Energies**, v. 7, n. 9, p. 5787–5824, 2014.

BASSAMZADEH, N.; GHANEM, R.; LU, S.; KAZEMITABAR, S. J. Robust scheduling of smart appliances with uncertain electricity prices in a heterogeneous population. **Energy and Buildings**, v. 84, p. 537–547, 2014.

BATCHU, R.; PINDORIYA, N. M. Residential Demand Response Algorithms: State-of-the-Art, Key Issues and Challenges. **Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST**, v. 154, n. 2, p. 18–32, 2015.

BEAUDIN, M.; ZAREIPOUR, H. Home Energy Management Systems: A Review of Modelling and Complexity. In: **Energy Solutions to Combat Global Warming**. New York, NY: Springer International Publishing, 2017. p. 753–793.

BURER, S.; LETCHFORD, A. N. Non-convex mixed-integer nonlinear programming: A survey. **Surveys in Operations Research and Management Science**, v. 17, n. 2, p. 97–106, 2012.

CHALISE, S.; STERNHAGEN, J.; HANSEN, T. M.; TONKOSKI, R. Energy management of remote microgrids considering battery lifetime. **Electricity Journal**, v. 29, n. 6, p. 1–10, 2016.

CHAVALI, P.; YANG, P.; NEHORAI, A. A distributed algorithm of appliance scheduling for home energy management system. **IEEE Transactions on Smart Grid**, v. 5, n. 1, p. 282–290, 2014.

CHAVES, A. A. **Uma meta-heurística híbrida com busca por agrupamentos aplicada a problemas de otimização combinatória**. 2009. Tese (Doutorado em Computação Aplicada) - Departamento de Computação Aplicada, INPE, São José dos Campos, 2009.

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

CHOOTINAN, P.; CHEN, A. Constraint handling in genetic algorithms using a gradient-based repair method. **Computers and Operations Research**, v. 33, n. 8, p. 2263–2281, 2006.

CLERC, M.; KENNEDY, J. The particle swarm - explosion, stability, and convergence in a multidimensional complex space. **IEEE Transactions on Evolutionary Computation**, v. 6, n. 1, p. 58–73, 2002.

COELLO, C. Theoretical and numerical constraint-handling techniques used with evolutionary algorithms: a survey of the state of the art. **Computer methods in applied mechanics and engineering**, v. 191, n. 11, p. 1245–1287, 2002.

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.

DENG, R.; YANG, Z.; CHOW, M. Y.; CHEN, J. A survey on demand response in smart grids: Mathematical models and approaches. **IEEE Transactions on Industrial Informatics**, v. 11, n. 3, p. 570–582, 2015.

DOE, U. S. D. of E. Benefits of Demand Response in Electricity Markets and Recommendations for Achieving Them. **US Dept. Energy, Washington, DC, USA, Tech. Rep**, 2006.

DONG, Y.; TANG, J.; XU, B.; WANG, D. An application of swarm optimization to nonlinear programming. **Computers & Mathematics with Applications**, v. 49, n. 11–12, p. 1655–1668, 2005.

EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. **Proceedings of the Sixth International Symposium on Micro Machine and Human Science**, p. 39–43, 1995.

ESTHER, B. P.; KUMAR, K. S. A survey on residential Demand Side Management architecture, approaches, optimization models and methods. **Renewable and Sustainable Energy Reviews**, v. 59, p. 342–351, 2016.

FARIA, P. N. da S. **Demand Response in future power systems management—A conceptual framework and simulation tool**. 2011. Polytechnic of Porto, 2011.

FARIA, P.; VALE, Z. Demand response in electrical energy supply: An optimal real time pricing approach. **Energy**, v. 36, n. 8, p. 5374–5384, 2011.

FARIA, P.; VALE, Z.; SOARES, J.; FERREIRA, J. Demand Response Management in Power Systems Using a Particle Swarm Optimization Approach. **Intelligent Systems, IEEE**, v. PP, p. 1, 2011.

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

GELLINGS, C. W. **The Smart Grid: Enabling Energy Efficiency and Demand Response**. 1st. ed. Boca Raton, FL: CRC Press, 2009.

GELLINGS, C. W. Evolving practice of demand-side management. **Journal of Modern Power Systems and Clean Energy**, v. 5, n. 1, p. 1–9, 2017.

GELLINGS, C. W.; CHAMBERLIN, J. H. **Demand-Side Management: Concepts & Methods**. 2nd. ed. Tulsa, OK: PennWell Books, 1993.

GLOVER, F. Future Paths for Integer Programming and Links to Artificial Intelligence. **Computers and Operations Research**, v. 13, n. 5, p. 533–549, 1986.

GOLDBARG, M. C.; GOLDBARG, E. G.; LUNA, H. P. L. **Otimização combinatória e meta-heurísticas: algoritmos e aplicações**. 1. ed. ed. Rio de Janeiro: Elsevier, 2016.

HA, D. L.; PLOIX, S.; ZAMAI, E.; JACOMINO, M. Metaheuristics for the home load management system. 2009.

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

HE, Y.; WANG, B.; WANG, J.; XIONG, W.; XIA, T. Residential demand response behavior analysis based on Monte Carlo simulation: The case of Yinchuan

in China. **Energy**, v. 47, n. 1, p. 230–236, 2012.

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

HUANG, Y.; WANG, L.; GUO, W.; KANG, Q.; WU, Q. Chance Constrained Optimization in a Home Energy Management System. **IEEE Transactions on Smart Grid**, v. 13, n. 9, p. 1–1, 2016.

INNOCENTE, M. S.; SIENZ, J. Particle Swarm Optimization with Inertia Weight and Constriction Factor. **International Conference on Swarm Intelligence**, p. 1–11, 2011.

JAVOID, N.; JAVOID, S.; WADOOD, A.; AHMED, I.; ALMOGREN, A.; NIAZ, I. A. A hybrid genetic wind driven heuristic optimization algorithm for demand side management in smart grid. **Energies**, v. 10, n. 3, p. 319, 2017.

KENNEDY, J.; EBERHART, R. C. A discrete binary version of the particle swarm algorithm. **1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation**, v. 5, p. 4104–4108, 1997.

KONONOVA, A. V.; CORNE, D. W.; DE WILDE, P.; SHNEER, V.; CARAFFINI, F. Structural bias in population-based algorithms. **Information Sciences**, v. 298, p. 468–490, 2015.

LEE, J. W.; LEE, D. H. Residential electricity load scheduling for multi-class appliances with Time-of-Use pricing. **2011 IEEE GLOBECOM Workshops, GC Wkshps 2011**, p. 1194–1198, 2011.

LIU, R.-S. An Algorithmic Game Approach for Demand Side Management in Smart Grid with Distributed Renewable Power Generation and Storage. **Energies**, v. 9, n. 8, p. 654, 2016.

LOGENTHIRAN, T.; MEMBER, S.; SRINIVASAN, D.; MEMBER, S.; SHUN, T. Z. Demand Side Management in Smart Grid Using Heuristic Optimization. v. 3, n. 3, p. 1244–1252, 2012.

LOGENTHIRAN, T.; SRINIVASAN, D.; PHYU, E. Particle Swarm Optimization for Demand Side Management in Smart Grid. **Smart Grid Technologies - Asia (ISGT ASIA), 2015 IEEE Innovative**, 2015.

LUZIA, L. F.; RODRIGUES, M. C. **Introdução ao Escalonamento e Aplicações: Estudo sobre as Metaheurísticas**. São Paulo, SP: Escola de Artes,

Ciências e Humanidades da Universidade de São Paulo, 2009. .

MOHSENIAN-RAD, A.-H.; WONG, V. W. S.; JATSKEVICH, J.; SCHOBER, R.; LEON-GARCIA, A. Autonomous Demand Side Management Based on Game-Theoretic Energy Consumption Scheduling for the Future Smart Grid. **IEEE Transactions on Smart Grid**, v. 1, n. 3, p. 320–331, 2010.

OGWUMIKE, C.; SHORT, M.; ABUGCHEM, F. Heuristic optimization of consumer electricity costs using a generic cost model. **Energies**, v. 9, n. 1, 2016.

OSMAN, I. H.; LAPORTE, G. Metaheuristics: A bibliography. **Annals of Operations Research**, v. 63, n. 5, p. 511–623, 1996.

PALENSKY, P.; DIETRICH, D. Demand side management: Demand response, intelligent energy systems, and smart loads. **IEEE Transactions on Industrial Informatics**, v. 7, n. 3, p. 381–388, 2011.

PFLUGRADT, N. **Load Profile Generator**. Disponível em: <<http://www.loadprofilegenerator.de/>>. Acesso em: 23 jul. 2016.

PIOTROWSKI, A. P.; NAPIORKOWSKI, J. J. Searching for structural bias in particle swarm optimization and differential evolution algorithms. **Swarm Intelligence**, v. 10, n. 4, p. 1–47, 2016.

R CORE TEAM. **R: a language and for statistical computing**. Disponível em: <<https://www.r-project.org>>. Acesso em: 1 dez. 2016.

REMANI, T.; JASMIN, E. A.; AHAMED, T. P. Load scheduling with Maximum Demand using Binary Particle Swarm Optimization. **2015 International Conference on Technological Advancements in Power and Energy (TAP Energy)**, p. 294–298, 2015.

SHI, Y.; EBERHART, R. C. Empirical study of particle swarm optimization. **Evolutionary Computation, 1999. CEC 99. Proceedings of the 1999 Congress on**, v. 3, p. 1–1950 Vol. 3, 1999.

SIANO, P. Demand response and smart grids - A survey. **Renewable and Sustainable Energy Reviews**, v. 30, p. 461–478, 2014.

SIEBERT, L. C.; AOKI, A. R.; YAMAKAWA, E. K.; TOLEDO, F. O. **Gerenciamento pelo Lado da Demanda em Redes Inteligentes Utilizando Algoritmos Genéticos**. Goiânia, GO: IV SBSE – Simpósio Brasileiro de Sistemas Elétricos, 2012. .

SILVA, H. B. da. **Resposta à Demanda via Precificação em Tempo Real para Controle da Demanda de Energia**. 2013. Dissertação (Mestrado em Engenharia de

Produção) - Departamento de Engenharia de Produção; Universidade Federal de Minas Gerais; Belo Horizonte, 2013.

SPAVIERI, G.; FERNANDES, R. A. S.; VALE, Z. Gravitational Search Algorithm Applied for Residential Demand Response Using Real-Time Pricing. **International Conference on Practical Applications of Agents and Multi-Agent Systems**, v. 619, p. 101–111, 2017.

TEIXEIRA, C. P.; FERREIRA, V. H. Gerenciamento da demanda residencial utilizando métodos de otimização natural e considerando a geração distribuída. **Simpósio Brasileiro de Sistemas Elétricos**, 2014.

U.S. DEPARTMENT OF ENERGY FEDERAL ENERGY REGULATORY COMMISSION. **A National Assessment of Demand Response Potential**. Washington, DC: Federal Energy Regulatory Commission (FERC), 2009.

UTURBEY, W. **Modelagem de Efeitos Intertemporais no Fluxo de Potência Ótimo: Abordagem pelo Lado da Demanda**. 2002. Universidade Federal de Santa Catarina, 2002.

VALLE, Y.; MEMBER, S.; VENAYAGAMOORTHY, G. K.; MEMBER, S.; HARLEY, R. G. Particle Swarm Optimization: Basic Concepts , Variants and Applications in Power Systems. **Power**, v. 12, n. 2, p. 171–195, 2008.

VARDAKAS, J.; ZORBA, N. A survey on demand response programs in smart grids: Pricing methods and optimization algorithms. **Surveys & Tutorials**, 2015.

VOS, S.; MARTELLO, S.; OSMAN, I. H.; ROUCAIROL, C. **Meta-Heuristics - Advances and Trends in Local Search Paradigms for Optimization**. [s.l.] Springer US, 1999.

WICKHAM, H. **Ggplot2: Elegant Graphics for Data Analysis**. 1. ed. New York: Springer, 2009.

WILKINSON, L. **The Grammar of Graphics**. 2nd. ed. New York: Springer, 2005.

XIA, W.; WU, Z. An effective hybrid optimization approach for multi-objective flexible job-shop scheduling problems. **Computers & Industrial Engineering**, v. 48, n. 2, p. 409–425, 2005.

ZAFAR, A.; SHAH, S.; KHALID, R.; HUSSAIN, S. M.; RAHIM, H.; JAVAID, N. A Meta-Heuristic Home Energy Management System. **2017 31st International Conference on Advanced Information Networking and Applications Workshops (WAINA)**, p. 244–250, 2017.

ZHOU, Y.; CHEN, Y.; XU, G.; QI ZHANG; KRUNDEL, L. Home energy management with PSO in smart grid. **2014 IEEE 23rd International Symposium on Industrial Electronics (ISIE)**, n. June, p. 1666–1670, 2014a.

ZHOU, Y.; CHEN, Y.; XU, G.; ZHENG, C. Home Energy Management From Demand Side in Smart Grid. **Innovative Smart Grid Technologies-Asia (ISGT Asia), 2014 IEEE**, p. 180–185, 2014b.

ZOBBA, A.; VACCARO, A. **Computational Intelligence Applications in Smart Grids**. Imperial College Press, 2015.

Apêndice A

PRODUÇÕES ACADÊMICAS

PUBLICADOS:

WILMERS, J. T. A. V. L.; CAVALCA, D.L.; FERNANDES, R. A. S. Análise Bibliométrica da Área de Pesquisa denominada *Demand Response*. In: **Encontro Regional de Estudantes de Biblioteconomia, Documentação, Ciência e Gestão da Informação**, 4., 2017, Porto Alegre. **Anais...** Porto Alegre: UFRGS, 2017. p.253-267.

CARVALHO, C. U.; SANCHES, S. P.; CAVALCA, D. L. Transporte Público Em Áreas Rurais: Uma Análise Bibliométrica. In: **Congresso Nacional de Pesquisas em Transportes da ANPET**, 31., 2017, Recife. **Anais...** Recife: ANPET, 2017.

ACEITOS:

CAVALCA, D. L.; SPAVIERI, G.; FERNANDES, R. A. S. *Comparative Analysis Between Particle Swarm Optimization Algorithms Applied to the Price-Based Demand Response Problem*. In: **International Conference on Artificial Intelligence and Soft Computing**, 17., 2018, Zakopane (Polônia).

SPAVIERI, G.; CAVALCA, D. L.; FERNANDES, R. A. S. *An Adaptive Individual Inertia Weight Based on Best, Worst and Individual Particle Performances for the PSO Algorithm*. In: **International Conference on Artificial Intelligence and Soft Computing**, 17., 2018, Zakopane (Polônia).

SUBMETIDOS:

CAVALCA, D. L.; FERNANDES, R. A. S. *Gradient-based Mechanism For PSO Algorithm: A Comparative Study On Numerical Benchmarks*. In: **IEEE Congress on Evolutionary Computation**, 2018, Rio de Janeiro.

CAVALCA, D. L.; FERNANDES, R. A. S. *Hybrid Particle Swarm Algorithm Applied to Flexible Job-Shop Problem*. In: IEEE Congress on Evolutionary Computation, 2018, Rio de Janeiro.