

**Universidade Federal do Amazonas
Instituto de Computação
Programa de Pós-Graduação em Informática**

**UM MÉTODO DE PROGRAMAÇÃO DE HORÁRIOS DE
EXECUÇÃO DE APARELHOS ELÉTRICOS PARA MINIMIZAR
O CUSTO NO CONSUMO DE ENERGIA EM AMBIENTES
INTELIGENTES**

Francisco Ivan Rodrigues de Andrade

Manaus - AM
2015

Francisco Ivan Rodrigues de Andrade

**UM MÉTODO DE PROGRAMAÇÃO DE HORÁRIOS DE
EXECUÇÃO DE APARELHOS ELÉTRICOS PARA MINIMIZAR
O CUSTO NO CONSUMO DE ENERGIA EM AMBIENTES
INTELIGENTES**

Dissertação apresentada ao Programa de Pós-graduação em Informática da Universidade Federal do Amazonas como requisito para obtenção do grau de Mestre em Informática. Área de concentração: Redes de Computadores e Telecomunicações.

Orientador: Prof. Dr. Eduardo James Pereira Souto

Manaus - AM
2015

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

A553u Andrade, Francisco Ivan Rodrigues de
Um método de programação de horários de execução de
aparelhos elétricos para minimizar o custo no consumo de energia
em ambientes inteligentes / Francisco Ivan Rodrigues de Andrade.
2015
82 f.: il. color; 31 cm.

Orientador: Eduardo James Pereira Souto
Dissertação (Mestrado em Informática) - Universidade Federal do
Amazonas.

1. Otimização. 2. Busca Tabu. 3. Metaheurística. 4. Ambientes
Inteligentes. I. Souto, Eduardo James Pereira II. Universidade
Federal do Amazonas III. Título

Dedicado à minha mãe e ao meu pai.

E o fim é belo incerto... depende de como você vê o novo, o credo, a fé que você deposita em você e só.
(Fernando Anitelli)

Agradecimentos

Os agradecimentos descritos aqui são proferidos para todos aqueles que me fizeram acreditar na realização deste trabalho ao longo de toda essa jornada e que contribuíram direto e/ou indiretamente.

Agradeço ao meu Deus pela fé direcionada, saúde e proteção.

Agradeço a minha família: meu pai, Sr. Antônio Andrade, minha mãe Sra. Maria Laurenno, ao meu irmão Francisco Andrade, as minhas irmãs Gleivani e Ivaneide, e a minha noiva Evelyne, pelo apoio incondicional, por estarem longe, mas sempre ao meu lado em pensamentos positivos, orações e votos de sucesso.

Agradeço ao meu orientador Dr. Eduardo Souto, pela paciência e condução no desenvolvimento deste trabalho, compartilhando seu conhecimento e ensinamentos necessários para a formação do profissional que me tornarei.

Aos meus colegas de laboratórios que não ousarei listar nomes sob risco de esquecer algum nome equivocadamente pelo acompanhamento, companheirismo e força.

Agradeço a todo o colegiado do IComp, pelo profissionalismo e empenho na condução do programa de pós, elevando a cada dia o nome da instituição nos patamares de renome nacional e internacional.

Aos meus amigos que sempre me deram apoio.

À diretoria de gestão da Eletrobrás Distribuidora de Energia pela cessão e liberação com horário flexível para a realização dos estudos. Agradeço ainda os Srs. André Couto pela oportunidade de aprendizado e desenvolvimento das habilidade gestoras e pela força no decorrer deste tempo, ao Sr. Teodomiro Raposo, por ensinar tanto de maneira tão simples e pelo respeito que sempre me dedicou.

Meu muito obrigado.

Resumo

A busca pela eficiência energética representa atualmente um dos principais desafios mundiais. Em função do cenário crescente de demanda de energia, políticas públicas relacionadas a mudanças na estrutura tarifária das contas de energia têm sido aplicadas na tentativa de melhorar a utilização dos recursos energéticos e evitar colapsos no setor de energia elétrica brasileiro. Tal fato torna cada vez mais evidente a necessidade de conhecer e gerenciar o consumo de energia residencial.

Dessa forma, sistemas de gerenciamento de energia residencial têm sido propostos para o monitoramento e controle da infraestrutura elétrica e dos eletrodomésticos em residências. No entanto, a maioria das soluções existentes é projetada com escopo limitado, tais como controle de iluminação com detecção de movimento, controle do clima com base na temperatura interna do ambiente, e controle para ligar e desligar aparelhos elétricos. Para superar estas limitações, estudos têm sido realizados com o objetivo de fornecer funcionalidades que permitam minimizar o consumo e o custo de energia em função do número e perfil das pessoas na residência. Na literatura há trabalhos que geram programações para a execução dos aparelhos considerando diferentes variáveis e restrições como potência de aparelho, tempo de execução, tarifa variável por horário e balanceamento de uso dos aparelhos para fora do horário de ponta, a combinação desse grande número de variáveis caracteriza um problema de otimização de complexidade NP-difícil.

Para superar este problema, este trabalho propõe um método, denominado Zippy, que auxilia na redução do custo de energia por meio de uma programação de horários de execução dos aparelhos, satisfazendo ao mesmo tempo um conjunto de restrições pré-definidas. O método proposto utiliza a metaheurística Busca Tabu para auxiliar na geração de programação de execução de aparelhos em intervalos de tempo mais viáveis economicamente. Experimentos realizados com uma base de dados de uma residência mostram que o método é capaz de fornecer boas programações adquirindo uma economia geral de até 46% quando comparado com os custos originais obtidos sem a aplicação do método.

Palavras-chave: Otimização, Busca Tabu, Metaheurística, Ambientes Inteligentes.

Abstract

Search for energy efficiency is currently one of the main global challenges. Energy demand is growing and this is attributed to increased energy consumption in homes. In this scenario of a big energy demand, public policies related to changes in the tariff structure of the bills have been applied in an attempt to improve the use of energy resources and prevent collapses in the Brazilian electric sector. It is becoming evident that the knowledge and the management of residential energy consumption need to be improved.

Thus, home energy management systems have been proposed for monitoring and control of electrical infrastructure and appliances in homes. However, most existing solutions are designed with limited scope such as lighting control with motion detection, climate control based on ambient temperature and control of turning on and off electrical appliances. To overcome these limitations, studies have been conducted with the aim of providing features that minimize power consumption and energy costs based on the quantity of people in the residential and their profiles.

Studies in the literature seek to generate schedules for the implementation of appliances considering different variables and constraints such as appliance power, runtime, variable rate by time, balanced usage of appliances out off-peak hours and user criteria of comfort/preference, featuring a NP-Hard optimization problem.

To solve this problem, we propose in the work a method called Zippy, which assists the reduction of energy cost through running appliances schedules while meeting a set of predefined constraints. The proposed method uses Tabu Search metaheuristic to assist in the appliance execution schedule in a more economically way. Experiments carried out in a database from a home showed that the method is able to provide good programming acquiring an overall savings of up to 46% compared with the original cost obtained without the method.

Keywords: Optimization, Tabu Search, Metaheuristic, Smart Environments.

Sumário

LISTA DE FIGURAS.....	XI
LISTA DE TABELAS.....	XII
LISTA DE SIGLAS.....	XIII
INTRODUÇÃO	14
1.1. Motivação	17
1.2. Objetivos	18
1.3. Estrutura da Dissertação.....	19
CONCEITOS BÁSICOS E TRABALHOS RELACIONADOS.....	20
2.1. Conceitos Básicos.....	20
2.2. Busca Tabu	22
2.3. Enxame de Partículas	25
2.4. Algoritmo Genético	32
2.5. Programação Linear Inteira Mista.....	36
2.6. Outras Técnicas	38
2.7. Considerações Finais	46
MÉTODO DE MINIMIZAÇÃO DE CONSUMO DE ENERGIA – ZIPPY.....	49
3.1. Método Proposto.....	49
3.1.1. Modelo de Programação de Serviços	50
3.1.2. Busca Tabu Proposta	55
3.2. Considerações Finais	58
EXPERIMENTOS E RESULTADOS	59
4.1. Protocolo Experimental	59

4.1.1.	Cenário.....	59
4.1.2.	Detalhamento da Base de Dados	62
4.1.3.	Hardware e Software utilizados nos Experimentos	64
4.1.4.	Métricas de Avaliação	64
4.2.	Resultados.....	65
4.3.	Considerações Finais	73
CONCLUSÕES E TRABALHOS FUTUROS.....		75
REFERÊNCIAS.....		78

Lista de Figuras

Figura 1.1. Comparativo entre a tarifa branca e tarifa convencional [Aneel, 2010a].	15
Figura 2.1. Arquitetura do sistema de controle de edifício aplicando o <i>PSO</i> , adaptado de [Rui et al., 2011].	28
Figura 2.2. Sistema multiagente para controle de energia de edifício utilizando o algoritmo de Enxame de Partículas, adaptado de [Rui & Lingfeng, 2011].	29
Figura 2.3. Modelo do sistema de economia de energia em escritório com módulo de controle sem fio utilizando <i>PSO</i> , adaptado de Wa et al. [2011].	30
Figura 2.4. Arquitetura do modelo de decisão para gerenciamento de energia residencial baseado na Programação Linear Inteira Mista, adaptado de Agnetis et al. [2013].	38
Figura 2.5. Sistema de gerenciamento de demanda de energia utilizando Programação Linear Inteira, adaptado de Barbato et al. [2011].	41
Figura 2.6. Arquitetura da ferramenta de simulação de gestão de energia usando Enxame de Partículas Binário, adaptado de Gudi et al. [2010].	42
Figura 2.7. Modelo de otimização e controle preditivo de temperatura proposto com uso de Enxame de Partículas, adaptado de Arpaia et al. [2010].	46
Figura 3.1. Diagrama da Busca Tabu proposta.	56
Figura 3.2. Estratégia de vizinhança para Busca Tabu, adaptada de [Glover, 1997].	57
Figura 4.1. Sensores instalados no ambiente de teste [Tapia, 2003].	60
Figura 4.2. Mapa do apartamento com a disposição dos sensores e aparelhos instalados no ambiente de teste [Tapia, 2003].	60
Figura 4.3. Consumo dos aparelhos elétricos em watts.	64
Figura 4.4. Referências de horários variados da Tarifa Branca, adaptado de [Aneel, 2010a].	65
Figura 4.5. Intervalo de execução dos aparelhos elétricos no dia 27/03/2003.	66
Figura 4.6. Intervalo de execução dos aparelhos elétricos no dia 03/04/2003.	66
Figura 4.7. Procedimento de otimização realizado no dia 03/04/2003.	68
Figura 4.8. Programação padrão dos serviços do dia 27/03/2003.	69
Figura 4.9. Programação otimizada dos serviços sem critérios de preferência do usuário do dia 27/03/2003.	70
Figura 4.10. Programação otimizada dos serviços com critérios de preferência do usuário do dia 27/03/2003.	70
Figura 4.11. Comparativo de custo no consumo de energia durante 16 dias.	72
Figura 4.12. Análise de desempenho do algoritmo com diferentes parâmetros de lista tabu.	73

Lista de Tabelas

Tabela 2.1. Análise comparativa dos trabalhos relacionados.	47
Tabela 3.1. Intervalo de tempo de acordo com a tarifa branca de energia.	51
Tabela 3.2. Intervalos de potência dos aparelhos e seus respectivos pesos.....	51
Tabela 3.3. Possível conjunto de serviços para solução inicial.	52
Tabela 4.1. Dispositivos alocados por cômodo.....	61
Tabela 4.2. Lista de dispositivos utilizados nos experimentos.	62
Tabela 4.3. Percentual de economia adquirido com a aplicação do método Zippy.....	72

Lista de Siglas

ABLE	<i>Autonomous Balancing of Load Energy</i>
AG	Algoritmo Genético
ANEEL	Agência Nacional de Energia Elétrica
AIE	Agência Internacional de Energia
BEMS	<i>Building Energy Management System</i>
BPSO	<i>Binary Particle Swarm Optimization</i>
BT	Busca Tabu
DSM	<i>Demand-Side Management</i>
EPE	Empresa de Pesquisa Energética
EPMO	Enxame de Partículas Multiobjetivo
EUA	Estados Unidos da América
GMBA	<i>Global Model Based Anticipative</i>
GSO	<i>Glowworm Swarm Optimization</i>
GW	Gigawatts
HEMP	<i>Household Energy Management Problem</i>
HEMS	<i>Home Energy Management System</i>
HVAC	<i>Heating Ventilation Air Conditionary</i>
IHM	Interface Homem-Máquina
KW	<i>Quilowatts</i>
ME2S	Método de Energia para Serviços
MIT	<i>Massachusetts Institute of Technology</i>
MW	<i>Megawatts</i>
NILM	<i>Non-Intrusive Load Monitoring</i>
ONS	Operador Nacional do Sistema
PLIM	Programação Linear Inteira Mista
PNLIM	Programação Não-Linear Inteira Mista
PSO	<i>Particle Swarm Optimization</i>
RSSF	Rede de Sensores Sem Fio
SFLA	<i>Shuffled Frog Leaping Algorithm</i>
SI	<i>Swarm Intelligence</i>
SIN	Sistema Interligado Nacional
TIC	Tecnologia da Informação e Comunicação
TS	<i>Tabu Search</i>
TUSD	Tarifa de Uso do Sistema de Distribuição

Capítulo 1

Introdução

A busca pela eficiência energética representa atualmente um dos principais desafios mundiais. De acordo com o relatório da Agência Internacional de Energia (AIE) de 2014, a demanda mundial de energia crescerá 76% até 2020 e grande parte desse crescimento é devido ao aumento do consumo de energia nas residências [AIE, 2013]. No relatório é argumentado que esse crescimento se dará devido a diferentes fatores como o aumento da população, número de habitações ocupadas, mudanças no tamanho das habitações, crescimento no número de aparelhos elétricos e a melhoria da qualidade de vida da população.

Segundo relatórios da Agência Nacional de Energia Elétrica (ANEEL), no cenário brasileiro, há um crescimento médio de 5,8% ao ano, considerando a análise dos dados realizada nos anos 1973 até 2011 [Filho, 2013][Epe, 2012][Martins, 2013]. De acordo com esses estudos, o setor residencial apresenta um crescimento de consumo anual médio de 4,3%, comprovando a tendência mundial apresentada pela AIE.

Em função dessas análises e previsões, políticas públicas e mudanças na estrutura tarifária das contas de energia têm sido aplicadas na tentativa de melhor utilizar os recursos energéticos e evitar colapsos no setor de energia elétrica brasileiro [Guedes, 2011][Aneel, 2010a][Fujimoto, 2010][Aneel, 2015b].

Para o faturamento da demanda de energia consumida, a ANEEL define uma estrutura tarifária, um conjunto de tarifas aplicáveis aos componentes de consumo de energia elétrica e/ou demanda de potência ativa por unidade consumidora, de acordo com a modalidade de fornecimento [Guedes, 2011]. A estrutura tarifária é a forma como os diversos tipos de consumidores pagam pelo uso da energia elétrica, divididos por subgrupos e modalidades de tarifas de acordo com horas de uso, nível de tensão e localização.

Em 2015 foram adotadas no Brasil três modalidades de tarifas, a tarifa horosazonal azul, a tarifa horosazonal verde e a tarifa convencional, sendo que esta última é aplicada à classe residencial [Fujimoto, 2010]. A diferença entre as classes decorre da aplicação de postos tarifários e da forma de cobrança dos custos relativos à Tarifa de Uso do Sistema de Distribuição (TUSD) no horário de maior utilização do sistema, definido como horário de ponta.

Desde 2013, em caráter educativo, foi adicionado ao formato tradicional o formato de cobrança de bandeiras tarifárias: verde, amarela e vermelha [Aneel, 2015b]. Este formato funciona como um semáforo de trânsito e se refletirá em diferença de tarifa para o consumidor, este modelo passa a vigorar efetivamente a partir de 2017. Neste mesmo ano, está sendo testado um novo formato tarifário, a tarifa branca [Aneel, 2010a] que substituirá a modalidade convencional de fatura de energia residencial.

No novo sistema de tarifa branca, cada distribuidora de energia define um intervalo de três horas, entre as 17h e 22h, no qual o consumo de energia elétrica será mais caro. Neste horário de ponta a energia custará cinco vezes mais do que no horário de baixo consumo e três vezes mais do que no horário intermediário [Aneel, 2010a], conforme mostra a Figura 1.1.

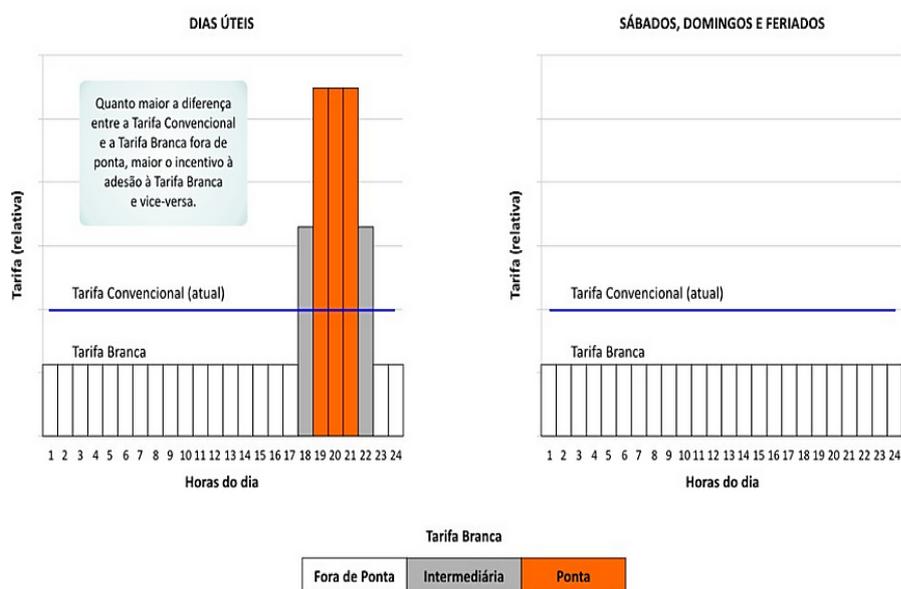


Figura 1.1. Comparativo entre a tarifa branca e tarifa convencional [Aneel, 2010a].

Dado o cenário de aumento da demanda do consumo de energia elétrica mundial e nacional, e das mudanças gradativas no setor elétrico brasileiro, cada vez mais é evidente a necessidade de conhecer e gerenciar o consumo de energia residencial.

Nesse contexto, sistemas de gerenciamento de energia residencial (do inglês, *Home Energy Management System - HEMS*) têm sido propostos para o monitoramento e controle da infraestrutura elétrica e dos eletrodomésticos em residências. No entanto, a maioria das soluções existentes é projetada com escopo limitado, tais como controle de iluminação com detecção de movimento, controle do clima com base na temperatura interna do ambiente e controle para ligar e desligar aparelhos elétricos [Tompos et al., 2009].

Na busca de tornar os *HEMS* mais eficientes, estudos têm sido propostos para fornecer funcionalidades que permitam minimizar o consumo e o custo de energia em função do número e perfil das pessoas na residência [Missaoui et al., 2014][Khomami & Javidi, 2013][Zhuang et al., 2013]. Nesses trabalhos, os *HEMS* passam a considerar diferentes variáveis e restrições como potência de aparelho, tempo de execução dos aparelhos eletrônicos, tarifa variável por horário, balanceamento de uso dos aparelhos para fora do horário de ponta (melhor distribuição no uso da rede elétrica) e critérios de conforto do usuário.

Diante do número de variáveis e restrições é possível caracterizar este problema de gestão de energia como um problema de otimização, de complexidade computacional NP-difícil, podendo ser formulado ainda como um problema de escalonamento de recursos. Neste problema, a energia é considerada como um recurso compartilhado por aparelhos eletrônicos, e os serviços correspondem ao uso dos aparelhos durante um intervalo de tempo a ser alocado para executar uma determinada atividade. De modo geral, o objetivo é reduzir o custo no consumo global de energia por meio de uma programação de serviços, satisfazendo ao mesmo tempo as restrições pré-definidas.

Para tratar esse problema, vários métodos têm sido aplicados: métodos exatos e métodos de otimização, como as metaheurísticas, conforme descrito na Seção 2.7. Os métodos exatos possuem uma característica de precisão no seu resultado, porém, dependendo do tamanho da instância, o tempo de processamento pode ser elevado em um grau exponencial [Duy et al.,

2012][Agnētis et al., 2013]. Por outro lado, as metaheurísticas como a Busca Tabu [Takeuchi et al., 2012], Exame de Partículas [Yinliang et al., 2013], Algoritmo Genético [Eunji & Hyokyung, 2014], entre outras [Eusuff et al., 2006][LEE, 2014], têm sido largamente utilizadas e vistas como opções mais vantajosas a serem exploradas [Takeuchi et al., 2012][Eunji & Hyokyung, 2014].

Metaheurísticas são métodos de solução que coordenam procedimentos de busca locais com estratégias de mais alto nível, capaz de escapar de mínimos locais e realizar uma busca robusta no espaço de soluções de um problema, podendo assim encontrar soluções globais muito próximas da solução ótima [Glover & Kochenbergh, 2003]. Assim, apesar de não garantir condições de otimalidade, como os métodos exatos, as metaheurísticas são capazes de convergir para boas soluções em tempo computacional razoável se bem projetadas.

Este trabalho utiliza a metaheurística Busca Tabu (BT) como o método para minimizar o custo no consumo de energia elétrica por meio da programação de serviços executados pelos aparelhos eletrônicos em uma residência. O uso da Busca Tabu como estratégia de otimização da programação de serviços é explorado, levando em conta o tratamento de variáveis de otimização que observam o tempo de execução de cada aparelho envolvido com o serviço, a potência elétrica dos aparelhos, o custo tarifário de energia e o nível de conforto estabelecido pelo usuário.

A escolha pelo uso da BT é devido aos seus bons resultados em problemas similares a natureza deste trabalho, como por exemplo, problemas de programação de horários [Missaoui et al., 2014][Takeuchi et al., 2012] e distribuição de carga [Eusuff et al., 2006][Jun et al., 2010]. A flexibilidade proporcionada pela BT é um fator diferencial perante os métodos exatos, sobretudo na sua capacidade de resultados considerados bons em um curto espaço de tempo.

1.1. Motivação

O aumento no número de aparelhos elétricos e da população fez a demanda de energia mundial crescer [Aie, 2015]. No Brasil, o governo vem aplicando uma série de ações reguladoras para tratar este problema da alta demanda e do gerenciamento de energia [Aneel, 2015b]. Como mencionado na seção anterior, uma das últimas ações foi o surgimento do novo método de

precificação brasileiro de energia, por meio da tarifa branca [Aneel, 2010a] que será aplicado nas residências brasileiras no ano de 2017.

Assim, a motivação deste trabalho surgiu do interesse em se investigar e buscar meios de melhorar a eficiência no consumo de energia elétrica em residências, levando em consideração a nova modalidade de precificação de energia a ser implantada no país.

É importante ressaltar que o problema é de natureza complexa, uma vez que trata com um conjunto grande de variáveis que precisam ser consideradas, tais como tarifa de horário variável ao longo do dia, diferentes tipos de potência de aparelhos, critérios de comodidade do usuário, uso de fontes alternativas de energia e até mesmo tratamento de demanda de consumo fora do horário de ponta.

A solução proposta é constituída de um algoritmo guloso responsável pela seleção prévia de um conjunto solução inicial, formado pelos aparelhos elétricos a serem programados, e um algoritmo de Busca Tabu, responsável por melhorar a combinação de programação deste conjunto de aparelhos por meio de seu procedimento de busca avançada, retornando a melhor solução global encontrada, ou seja, a relação de aparelhos com a programação de menor custo.

1.2. Objetivos

O objetivo geral deste trabalho consiste em desenvolver uma estratégia algorítmica para otimizar o gerenciamento de energia elétrica em ambientes residenciais.

Para atingir este objetivo geral são tratados os seguintes objetivos específicos:

1. Minimizar o custo de consumo de energia elétrica utilizando a metaheurística Busca Tabu, levando em conta os fatores de potência dos aparelhos, tempo de execução dos serviços, tarifa variável por horário e o conforto do usuário.
2. Programar execuções de serviços considerando o menor custo de consumo de energia, preservando a comodidade do usuário, quando solicitado.

3. Balancear o quantitativo de uso de aparelhos por faixa de horário para evitar a sobrecarga de consumo de energia nos horários de ponta no sistema elétrico.

1.3. Estrutura da Dissertação

O restante deste trabalho está estruturado da seguinte maneira:

- O Capítulo 2 aborda os principais conceitos e definições necessárias para o entendimento do tema abordado, além de apresentar alguns trabalhos relacionados ao emprego de técnicas de otimização para minimizar o consumo de energia.
- O Capítulo 3 mostra o modelo de programação de serviços e a função de custo utilizada para validar o método proposto, a partir das considerações das restrições de execução.
- O Capítulo 4 descreve o processo de experimentos realizados em cima de um cenário real, detalhado na seção 4.1. Este Capítulo discute ainda os resultados dos experimentos com o objetivo de demonstrar a viabilidade do método proposto.
- Por fim, o Capítulo 5 apresenta as conclusões do trabalho, relacionando os objetivos traçados inicialmente com os resultados alcançados. Além disso, o capítulo também apresenta propostas para trabalhos futuros.

Capítulo 2

Conceitos Básicos e Trabalhos Relacionados

Este Capítulo mostra os conceitos básicos que serão abordados no decorrer da dissertação e as pesquisas recentes relacionadas ao emprego de técnicas de otimização para minimizar o consumo de energia. Para realizar essa tarefa de forma mais organizada, os trabalhos relacionados neste Capítulo foram agrupados de acordo com o método heurístico empregado na solução proposta pelos autores.

Os trabalhos apresentados a seguir foram selecionados por meio de um processo de revisão sistemática considerando somente os trabalhos publicados a partir do ano de 2010, organizados pelos métodos mais comuns encontrados na literatura incluindo a Busca Tabu (Seção 2.1), o Enxame de Partículas (Seção 2.2), o Algoritmo Genético (Seção 2.3) e a Programação Linear Inteira Mista (PLIM) (Seção 2.4). A Seção 2.5 agrupa os trabalhos relacionados que empregam abordagens menos utilizadas. Por último, a Seção 2.6 sumariza os trabalhos apresentados.

2.1. Conceitos Básicos

- **Metaheurísticas**

Metaheurísticas são métodos heurísticos independentes de problemas específicos. Podendo ser utilizada na resolução de problemas pertencentes à diversos contextos, pois oferece abordagem a ser seguida que não se relaciona aos detalhes do problema. De maneira geral, são consideradas boas quando se busca obter soluções satisfatórias em um curto espaço de tempo computacional sobre problemas que não têm solução exata conhecida.

A área de estudo das metaheurísticas é considerada um subcampo primário da área de otimização, classe geral de algoritmos e técnicas que empregam algum grau de aleatoriedade para

encontrar soluções tão ótimas quanto possível para problemas reconhecidamente difíceis e que não se tem uma solução ótima fechada e conhecida [Luke, 2013].

Pela definição original, metaheurísticas são métodos de solução que coordenam procedimentos de busca locais com estratégias de mais alto nível, de modo a criar um processo capaz de escapar de mínimos locais e realizar uma busca robusta no espaço de soluções de um problema, buscando assim soluções globais muito próximas da solução ótima [Glover, 2003].

Uma metaheurística busca obter uma solução factível e satisfatória, porém sem qualquer garantia de otimalidade. Em geral, as metaheurísticas utilizam o conceito de vizinhança (explicado a seguir) para se estabelecer saltos aleatórios, ou seja, meios de escapar de mínimos locais. São aplicadas para encontrar respostas para problemas sobre os quais há poucas informações disponíveis e que possuem um grau elevado de complexidade, impedindo de chegar a uma solução ótima.

- **Vizinhança**

Um conjunto $N(x) \subseteq S$ é chamado de vizinhança de x , no qual uma função de vizinhança $N : S \rightarrow 2^S$ é especificada para cada solução $x \in S$. Assim, $N(x)$ é o tamanho da vizinhança de x , e uma solução x' é considerada vizinha de x se $x' \in N(x)$. Para a definição de uma vizinhança é comum fazer uso de algumas técnicas de busca local, como heurísticas [Glover & Kochenberger, 1986][Hansen, 1986].

- **Problema de Busca**

O objetivo de um problema de busca é obter uma solução viável para o problema, independentemente da qualidade. No entanto, o desejável é sempre um resultado ótimo, ou o mais próximo deste possível.

- **Problema de Otimização**

Em um problema de otimização busca-se adquirir uma solução viável e de boa qualidade. Várias abordagens podem ser utilizadas para obter a resolução do problema como, por exemplo,

programações inteiras para instâncias pequenas e heurísticas para instâncias maiores e complexas. O importante é que a solução obtida garanta um ótimo global ou esteja mais próxima do ótimo global.

- **Otimização Combinatória**

O objetivo buscado na resolução de um problema de otimização combinatória é encontrar uma solução ótima de $S^* \in S$, no qual S é um conjunto infinito. A otimização combinatória é desejável em: *i)* problemas de otimização linear, quando as variáveis são contínuas e apresentam um comportamento linear em relação às restrições e à função objetivo; *ii)* em problemas de programação não linear, quando a função objetivo ou as restrições apresentam algum tipo de não-linearidade; e *iii)* problemas de programação inteira, quando qualquer variável é impossibilitada de assumir valores contínuos, condicionando-se a assumir valores inteiros, o que leva a uma maior complexidade computacional em relação a tratamento de funções não lineares. Em todos os casos, a atenção está voltada para encontrar valores que representam uma solução ótima global. Maiores detalhes podem ser encontrados em [Goldbarg, 2005].

2.2. Busca Tabu

A Busca Tabu (BT) é um método heurístico genérico cujo funcionamento é similar a um método de busca local que varre o espaço de busca, realizando movimentos entre as soluções, trocando soluções encontradas neste processo de busca por uma solução considerada melhor, não se deixando ficar presa por soluções ótimas locais [Carlos, 2013]. A BT tem como objetivo adquirir soluções ótimas globais ou bem próximas destas.

A partir de uma dada solução inicial, a busca realiza movimentos no seu espaço vizinho com o objetivo de melhorar a solução a cada iteração. No entanto, certos movimentos são proibidos, se estiverem dentro de uma lista tabu. Essa lista serve para evitar que soluções já visitadas tornem a se repetir. A lista tabu utiliza uma estrutura de memória flexível e armazena os movimentos visitados por um período de tempo ou por um determinado número de iterações.

Uma memória de curto prazo é a utilização da lista tabu clássica que armazena |T| soluções e funciona numa estrutura de fila de tamanho fixo, curto, assim, quando uma nova solução entra, a mais antiga sai. Essa estratégia está fundamentada no fato de que na exploração do espaço de soluções, as soluções geradas há mais tempo possivelmente estão “distantes” da região do espaço sob análise e, como tal, não tem influência na escolha da próxima solução vizinha naquela região. Desta forma, armazenam-se apenas as soluções mais “próximas” da solução atual.

Quando uma memória de curto prazo não é suficiente para evitar que a busca fique presa em certas regiões do espaço de soluções uma memória de longo prazo é utilizada como alternativa. A memória de longo prazo pode armazenar atributos de suas soluções visitadas em sua trajetória para indicar quais foram as regiões e/ou soluções mais visitadas. Para cumprir este objetivo, a estratégia de diversificação (aleatória) é usada, de maneira geral a BT usa uma memória de longo prazo para encorajar o processo de busca a explorar regiões ainda não visitadas. A vantagem em se utilizar tal estratégia ao invés de promover uma simples reinicialização do algoritmo e que, com o uso de memória de longo prazo, diminui-se o risco de voltar a visitar uma mesma região do espaço de soluções, situação que poderia ocorrer no processo de reinicialização em vista da perda das informações anteriores.

Para evitar soluções ótimas locais, a Busca Tabu usa duas estratégias como forma de alternar as soluções encontradas: a diversificação (aleatório) e a intensificação (ótimo local). A diversificação faz uso da estrutura de memória para guardar as soluções geradas e redirecionar a pesquisa para regiões que não foram exploradas ainda, realizando longos saltos aleatórios entre uma região e outra, escapando de soluções ótimas locais. A intensificação realiza o processo contrário da diversificação, intensificando o processo de busca nas regiões vizinhas mais próximas. Estas duas estratégias auxiliam a busca para prevenir ciclos (ou *looping*).

A seguir são apresentados alguns trabalhos que empregam a metaheurística Busca Tabu como estratégia essencial para gerar programações para consumo de energia.

Takeuchi et al. [2012] apresentam dois programas de agendamento usando as metaheurísticas Busca Tabu (BT) e Algoritmo Genético (AG) para determinar horários de operação

de uma rede de energia. Os autores definem uma rede de energia como um sistema que utiliza a energia de maneira eficaz, possibilitando o controle de oferta e a demanda de energia elétrica.

O algoritmo proposto cria uma programação para o horário de funcionamento das diferentes fontes de energia que compõem um sistema de gestão de energia elétrica. As saídas de múltiplas fontes de energia são controladas com o objetivo de equilibrar a oferta e a demanda de energia. Os algoritmos de BT e AG são executados considerando um conjunto de restrições como o consumo de energia da rede elétrica, a capacidade das baterias, calor gerado a partir da energia natural, demanda por energia elétrica em um determinado horário e as estimativas de aquecimento. Estas informações são então usadas pelos algoritmos de otimização visando minimizar a emissão de CO₂ e diminuir o custo de energia.

A viabilidade da solução é demonstrada em dois ambientes, em um pavilhão na feira Expor 2005 e em um escritório no aeroporto central da cidade do Japão. Tanto a metaheurística BT quanto o AG demonstraram ser aplicáveis nas condições e restrições exigidas, com um bom desempenho na velocidade das respostas do sistema e eficiência das unidades geradoras de energia. A diferença média dos resultados entre a BT e AG foi de 2%, sendo que em 95% dos dias a BT apresentou melhores resultados. Entretanto, os autores ressaltam que as abordagens utilizadas podem não ser adequadas para gerar programações para redes de energia maiores, sendo necessários alguns ajustes.

Missaoui et al. [2014] fazem uso da metaheurística Busca Tabu como algoritmo de otimização para avaliação de um sistema de gestão de energia global baseada em modelo de antecipação (do inglês, *Global Model Based Anticipative Building Energy Management System – GMBA-BEMS*), capaz de realizar previsões de demanda de energia, auxiliando na tomada de decisão com até 24 horas de antecedência.

O *GMBA-BEMS* tem como objetivo minimizar o custo de energia elétrica residencial considerando o limite máximo de energia estabelecida pela concessionária de energia, tarifas de preço praticadas e os fatores de conforto estabelecidos pelo usuário.

Para validar o *GMBA-BEMS*, os autores simulam, usando a ferramenta *MatLab/Simulink*¹, um ambiente composto por: *i*) um conjunto de controladores, que controlam os equipamentos de uma casa (sistemas de climatização, bomba d'água, entre outros); *ii*) um conjunto de modelos que descrevem os aparelhos elétricos usados (controles de ligar/desligar, tempo de inicialização do equipamento, energia dissipada pelo equipamento, entre outros); *iii*) Uma descrição da casa contendo a temperatura, CO2 emitido e a iluminação em cada cômodo da casa; *iv*) um conjunto de sensores que fornece a temperatura indicada em cada cômodo.

Um estudo de caso baseado na variação dos preços das tarifas elétricas demonstra os benefícios do algoritmo proposto para reduzir a conta de energia elétrica em aproximadamente 20%.

Jun & Kanyu [2010] propõem um método de distribuição de carga elétrica baseado na metaheurística Busca Tabu, cujo objetivo é minimizar o consumo de energia de um sistema de climatização (*chiller water*) composto por várias unidades de água.

O método proposto usa um algoritmo de Busca Tabu para estimar a capacidade de saída de refrigeração através da medição do fluxo de água, da alimentação e do retorno de temperatura da água. A meta é atingir um bom nível de refrigeração com o mínimo de consumo de energia elétrica.

Para validar o método proposto experimentos foram realizados em duas unidades de climatização iguais, considerando um período de funcionamento de 2.400 horas no ano, cobrindo uma área de 18 mil metros quadrados e um total de carga de 1.700 Kw. Os resultados mostram que houve uma redução considerável no consumo de energia, chegando a uma economia de 30% no período analisado em relação a abordagem sem o emprego do método de otimização.

2.3. Enxame de Partículas

Otimização por enxame de partículas (*Particle swarm optimization - PSO*) é uma técnica estocástica baseada em população de soluções inspirada no comportamento social da revoada de pássaros e de cardume de peixes [Kennedy & Eberhart, 1995].

¹ Ferramenta para simulação e execução de testes matemáticos e computacionais. Disponível em: <http://www.mathworks.com/>

O Enxame de Partículas faz parte do grupo que explora o comportamento coletivo para obter vantagens. Segundo Dréo et al. [2005] e Nascimento et al. [2013] a otimização por Enxame de Partículas evoluiu a partir do comportamento coletivo e considera que um único indivíduo é limitado, porém, quando está em grupo pode usar as características e as informações de seus vizinhos para melhorar a agilidade e robustez.

A população de agentes, denominados partículas, realizam movimentos de busca dentro do espaço do problema. A movimentação do agente leva em conta a própria experiência e das partículas vizinhas que constituem o enxame, ganhando assim maior eficácia no processo de busca.

O objetivo estratégico é ter todas as partículas em um local ótimo em um hiperplano. Este objetivo é adquirido por meio da atribuição de posições aleatórias, inicialmente para todas as partículas no espaço e em pequenas velocidades aleatórias, podendo ser melhorada com o tempo. O algoritmo é executado como em um processo de simulação, avançando posição por posição de cada partícula, baseado em sua velocidade, na posição corrente global conhecida e na melhor posição conhecida da partícula. A cada iteração e movimentação a função objetivo é apresentada. Dado um certo tempo, as combinações de exploração e movimentos de boas posições conhecidas no espaço fazem com que o coletivo de partículas convirjam todos para um local considerado ideal, ou o mais próximo deste.

A seguir são apresentados trabalhos que empregam a metaheurística *PSO* como estratégia principal para gerar agendamento de carga de energia para consumo.

Preocupados com o crescimento da demanda de energia elétrica em edifícios, Mangiatordi et al. [2013] propõem um modelo de agendamento de carga para a gestão inteligente de energia em residências com o objetivo de reduzir a diferença entre a potência elétrica média diária e o pico de demanda de carga.

O modelo proposto, baseado no algoritmo de otimização por Enxame de Partículas (do inglês, *Particle Swarm Optimization - PSO*), identifica os intervalos de tempo ideais para que os aparelhos domésticos sejam ligados para executar serviços solicitados pelo usuário com o objetivo de evitar picos de consumo. O sistema proposto é capaz de monitorar o consumo de energia de

cada modelo de eletrodoméstico a partir dos dados de consumo recebidos e armazenados em uma base de dados.

O sistema considera para otimização dois tipos de serviços: fixos e controláveis. Os serviços controláveis são aqueles que podem ser agendados e movimentados para execução em qualquer período de tempo de acordo com a restrição de início e término do serviço. Os serviços fixos ocorrem em um determinado período e não podem ser alterados.

O modelo proposto é implementado na ferramenta *MatLab*. A validação é realizada utilizando cenários domésticos (casas) com restrições quanto ao tempo de uso dos equipamentos. Os resultados mostram que o algoritmo é capaz de diminuir significativamente o pico médio da demanda de energia, alcançando um percentual de 37%. Além de demonstrar que a probabilidade de encontrar um perfil ideal de programação de uso dos equipamentos aumenta quando várias Enxame de Partículas são utilizadas para explorar o espaço de solução. Os autores observam ainda que o algoritmo converge rapidamente para uma solução próxima da ótima e que o emprego do *PSO* deve ser investigado quando novas atividades são adicionadas dinamicamente para um perfil de energia já programado.

Um sistema multiagente é projetado para o gerenciamento de energia em edifícios [Rui et al., 2011]. Como parte deste sistema a metaheurística de Enxame de Partículas é implementada para otimizar o sistema de controle, melhorar o conforto do usuário e economizar energia.

O sistema considera a operação de várias fontes geradoras de energia, porém são priorizadas as fontes de energia verde, como a energia solar e eólica. Além de minimizar o custo total de energia nas operações de um edifício, o sistema foi projetado para tratar restrições tal qual a emissão de gases poluentes.

A Figura 2.1 exibe a arquitetura do sistema dividido em camadas implementadas por meio de um conjunto de agentes. O agente coordenador central faz o controle através do otimizador (*PSO*), este é embarcado no agente central, que é responsável por coordenar e ajustar os pontos de controle das atividades. A camada de agentes controladores locais é composta por agentes específicos como agentes controladores de temperatura do ambiente, agentes controladores de iluminação e agentes controladores da qualidade do ar. Estes agentes são responsáveis por

executar as ações enviadas pela central, após o processamento e redirecionamento assinalado pelo agente de troca.

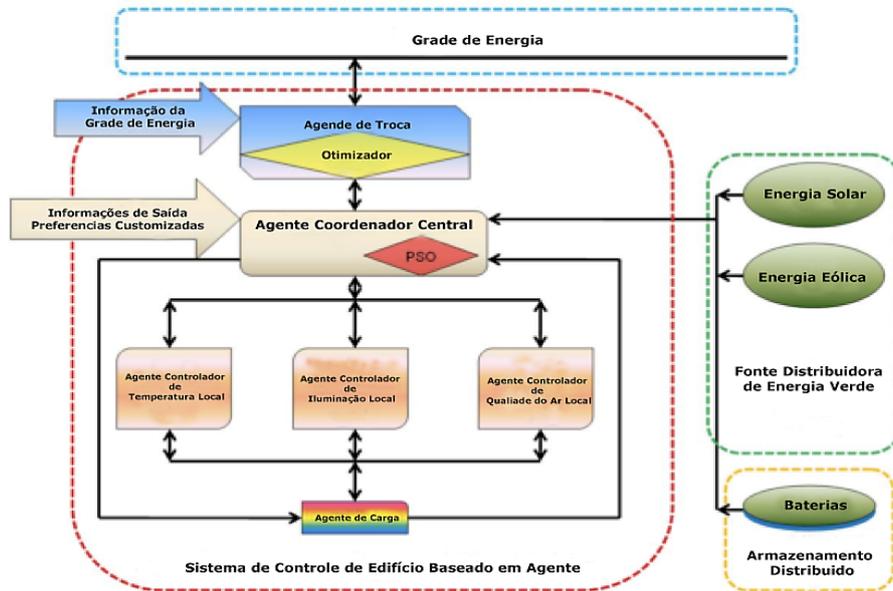


Figura 2.1. Arquitetura do sistema de controle de edifício aplicando o *PSO*, adaptado de [Rui et al., 2011].

Foram realizados experimentos com quatro estudos de casos considerando períodos de amostragem de 24 horas de operações em um edifício. Nos casos 1 e 2 foram comparados os resultados de conforto do edifício operando com fontes geradoras eólica e solar. Nos casos 3 e 4 foram verificadas a eficácia do otimizador para economizar custos com a energia e tiveram 0% de emissão de poluentes. De maneira geral foi possível otimizar consideravelmente o conforto e o consumo de energia com a aplicação do *PSO*.

Neste trabalho de pesquisa de Rui & Lingfeng [2011] é projetado um sistema multiagente para controlar os recursos energéticos dos cômodos de um edifício. Similar ao trabalho de Rui et al. [2011], o objetivo é agregar um ambiente confortável para os ocupantes e ao mesmo tempo garantir uma alta eficiência energética. O algoritmo de Enxame de Partículas também é utilizado para otimizar o gerenciamento de energia.

O sistema de multiagente proposto é composto por três tipos de agentes: um agente controlador central, agentes controladores locais e agentes de zonas. O controlador central possui um algoritmo de Enxame de Partículas que calcula o conforto geral do edifício e se reporta aos

ocupantes por meio de uma interface homem-computador. Os agentes controladores locais agem como atuadores executando as ações determinadas pelo agente central. Enquanto os agentes de zona calculam o conforto em zonas determinadas. Tais informações são repassadas para um agente central, conforme ilustrado na Figura 2.2. Para maximizar o conforto geral do edifício as variáveis de controle são funções de potência distribuída em cada zona.

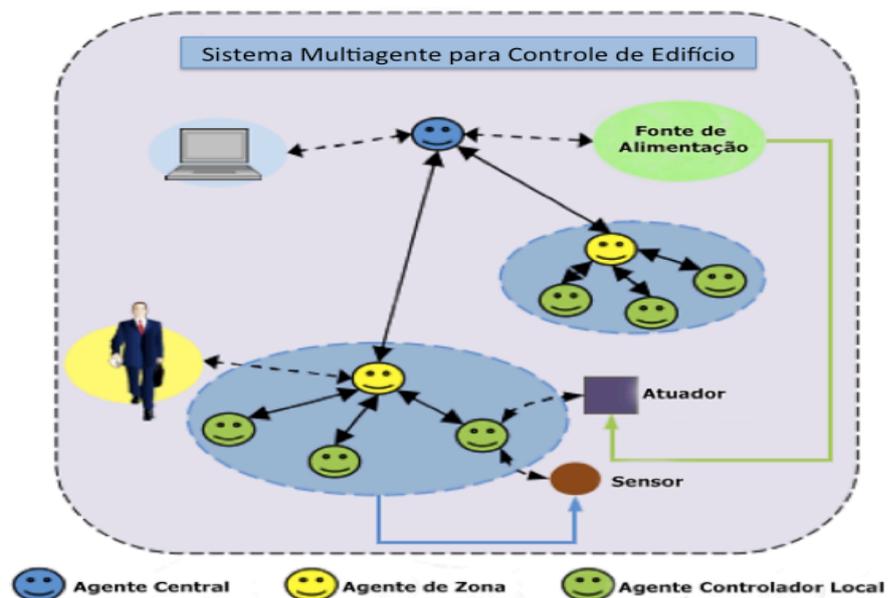


Figura 2.2. Sistema multiagente para controle de energia de edifício utilizando o algoritmo de Enxame de Partículas, adaptado de [Rui & Lingfeng, 2011].

As informações sobre potência demandada e o fornecimento de energia disponível são levantadas durante o processo de otimização. O controlador central então determina a distribuição de potência para cada zona. Assim, quando a energia disponível é maior do que a energia total demandada o controlador central distribui a energia exigida para cada zona, respeitando ainda as restrições e preferências atribuídas pelo ocupante, como limites de temperatura por exemplo. Caso contrário, a energia é distribuída entre as preferências atribuídas pelo ocupante.

Para validar o sistema proposto foi realizada uma simulação com um edifício, dividido em quatro zonas, considerando um período de 24 horas para coletar as variações de temperatura e de iluminação. Aquecedores, condicionadores de ar, luzes, persianas e ventiladores são utilizados na implementação do controle de ambiente físico. Os resultados apresentados mostram que o sistema

multiagente conseguiu distribuir a energia de forma adequada e manteve elevada as condições de conforto nos ambientes.

Wa et al. [2011] propõem um sistema de economia de energia para ambientes de escritório usando lâmpadas programáveis e rede de sensores sem fio. Um algoritmo de Enxame de Partículas é utilizado para otimizar e reduzir a quantidade de energia desperdiçada na iluminação do escritório com o intuito de contribuir para a redução do consumo global de energia elétrica.

Como mostra a Figura 2.3, sensores de luminosidade são empregados para coletar dados de iluminação natural do ambiente (produzida pela luz solar) e das luminárias (lâmpadas fluorescentes). Um módulo de controle de rede sem fio realiza o processamento desses dados usando um *PSO* para definir a melhor estratégia para economia de energia. Em seguida, o módulo de controle da rede envia comandos aos atuadores sem fio que controlam os dispositivos de iluminação, para que sejam efetuados os ajustes na iluminação do escritório.

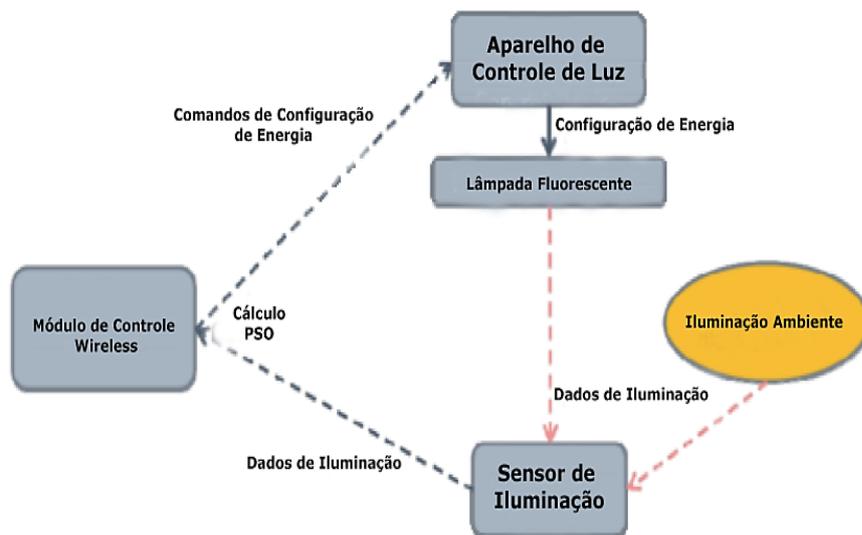


Figura 2.3. Modelo do sistema de economia de energia em escritório com módulo de controle sem fio utilizando *PSO*, adaptado de Wa et al. [2011].

Os testes para validação do sistema proposto foram realizados em um ambiente real composto de uma sala de escritório com 16 lâmpadas fluorescentes e 16 sensores (atuadores). Os resultados mostram que o sistema alcança índices de até 41,5% de economia de energia. Porém,

os autores salientam que o custo de processamento do *PSO* torna o sistema lento, principalmente quando o número de lâmpadas e de sensores aumenta.

Com o intuito de adquirir uma melhor gestão do uso de energia elétrica em um ambiente de rede elétrica inteligente, Abaza & Ahmed [2013] apresentam um método para gerenciamento de demanda de energia baseado em técnicas de precificação dinâmica.

O método utiliza o algoritmo *PSO* para tratar as restrições de custo e horário de utilização dos aparelhos, tornando possível realizar o deslocamento de um serviço para um intervalo de tempo considerado mais adequado. De modo resumido, o método realiza uma análise de carga considerando os aparelhos que só podem ser usados em horários diferenciados e aqueles que podem ser executados em qualquer horário.

Para a análise do método proposto, foi modelado um barramento elétrico, usando a ferramenta *MatLab*, que recebe um número de 108 cargas de consumo de energia e assume que o congestionamento de demandas de energia está acima de 85% da capacidade. O método se mostrou eficiente na gerência do congestionamento de cargas, reduzindo o pico de demanda e o custo operacional.

Uma abordagem de inteligência coletiva é aplicada para resolver o problema de distribuição de carga elétrica em uma usina térmica [Affijula & Chauhan, 2011]. Essa inteligência coletiva é obtida por meio de um algoritmo *PSO* programado para minimizar o custo total de combustível na usina, considerando o critério de equilíbrio de energia, em que a geração de cada unidade deve estar entre os limites máximos e mínimos da capacidade de geração, levando em conta que a energia gerada deve ser a mesma que a demanda de carga total mais as perdas totais de transmissão.

A validação da abordagem proposta é realizada através de dois cenários compostos por 13 e 40 unidades de geração térmica, simulados por meio da ferramenta *MatLab*. Para o primeiro cenário usando 13 unidades de geração térmica, o método *PSO* obteve melhores soluções quando comparado com o AG, neste caso, a sua função de custo convergiu para um baixo desvio padrão, levando em conta um total de 50 iterações. O resultado se mantém semelhante para o segundo caso, com 40 unidades de geração térmica. Assim, para estes cenários os resultados obtidos

mostraram que o *PSO* tem potencial no tratamento de problemas de otimização de grande porte sendo capaz de produzir bons resultados em pouco tempo.

Yinliang et al. [2013] apresentam um método baseado no *PSO* para otimizar a climatização (aquecimento e resfriamento) de edifícios comerciais e residenciais. O objetivo do método proposto é definir corretamente os pontos de temperatura de modo que o consumo total de energia e os custos possam ser minimizados, mantendo o conforto dos usuários. As variáveis de restrição: taxas de consumo de energia, perfil de carga, armazenamento de energia e condições meteorológicas são consideradas.

Recursos de pré-resfriamento e pré-aquecimento são utilizados como mecanismo para reduzir o pico de energia e manter o conforto do usuário. O método processa os melhores horários de início e término do serviço de resfriamento e aquecimento, realiza o cálculo do valor aproximado de custo de energia e o perfil de carga adequado para as condições climáticas identificadas internamente no ambiente.

Para a validação do método proposto as ferramentas *EnergyPlus* e *MatLab* foram utilizadas para modelar os edifícios e rodar os experimentos, respectivamente. Os autores fizeram uso de dados reais coletados no dia 24 de julho de 2010 da cidade de Pittsburg. Os resultados mostram que boas soluções de atribuição de pontos de temperaturas foram encontradas no período entre as 10h e 13h. Para o ponto de pré-resfriamento são atribuídos 21°C e para o resfriamento real 25°C. Desta forma, as cargas de energia consumida no horário de pico foram deslocadas para o horário fora de pico, levando economicidade nos custos de energia.

2.4. Algoritmo Genético

Algoritmo Genético (AG) é fundamentado no princípio da seleção natural do darwinismo. Holland [1975] descreve que o AG cria uma população de possíveis respostas para o problema a ser tratado, ou seja, a inicialização, para posteriormente submeter ao processo de evolução, percorrendo as etapas de avaliação, seleção, cruzamento, mutação, atualização e finalização. Goldberg [1989] enfatiza que os indivíduos que melhor se adaptam no processo mutação têm as melhores soluções para o problema aplicado.

Para Dréo et al. [2005] nos algoritmos genéticos os indivíduos submetidos à evolução são as soluções, considerados eficazes para um determinado problema. Os indivíduos evoluem durante uma sucessão de iterações, chamadas de gerações até que um critério de término leve a priori a qualidade das soluções obtidas.

A seleção e a variação são os mecanismos principais do AG. Na seleção é levado em conta o indivíduo mais adaptado, pois possui mais chances de sobreviver e deixar descendentes, fazendo com que o restante da população se movimente em relação à área mais apta, enquanto a variação consiste em inserir novos indivíduos na população por meio da recombinação genética.

A seguir são apresentados trabalhos que empregam o Algoritmo Genético como estratégia para gerar programações para consumo de energia de aparelhos eletrônicos.

Eunji & Hyokyung [2014] apresentam um método de programação de consumo de energia em edifícios inteligentes utilizando Algoritmos Genéticos (AGs). O objetivo é estabelecer uma programação de consumo de energia para aparelhos elétricos em tempo real e minimizar a carga total de energia elétrica consumida.

Neste trabalho são considerados os aparelhos elétricos comumente encontrados em um apartamento (televisor, geladeira, máquina de lavar, etc), medidores de consumo de energia e um sistema de preço de energia com tarifa de preços variáveis. A partir de um conjunto inicial de horários, o método proposto calcula a programação dos melhores horários, alterando de forma dinâmica o modo de operação de cada dispositivo de acordo com a variação dos preços da energia, em tempo real. Dessa forma, o uso do método proposto é capaz de reduzir o tempo de busca e encontrar uma programação razoável para os dispositivos, respeitando as restrições definidas de tempo e preço.

A validação da solução foi realizada por meio da implementação de um sistema de programação usando uma estratégia gulosa e o método AG proposto. Foram simulados cenários compostos por 50 a 300 aparelhos domésticos. Os resultados mostram que o emprego da estratégia gulosa possibilita uma economia média de 27% do consumo de energia enquanto que com o uso das programações fornecidas pelo método AG essa economia foi de 36,4% num período de 24 horas.

Khomami & Javidi [2013] apresentam uma arquitetura para sistemas de gerenciamento de energia em residências, composta por um modelo de resposta de demanda de energia automatizada para tratar a programação de serviços dos eletrodomésticos baseado em Algoritmo Genético.

O principal objetivo é proporcionar aos consumidores um controlador simples que possa ajudar na redução da conta e do consumo de energia durante o horário de pico, considerando as preferências de consumo e o critério de conforto dos usuários. De maneira geral, o sistema atua com base nas preferências de consumo, nas características de conveniência do usuário considerando a combinação de preço em tempo real, e um modelo de variação de preço para diminuir o consumo no horário de pico e melhorar o perfil de carga energética consumida.

O modelo busca minimizar o custo de energia, que está relacionado diretamente com consumo dos aparelhos que são geridos pelo sistema de gerenciamento de energia, considerando as restrições de consumo. O modelo leva em conta a divisão de uma hora em 10 intervalos de tempo, ou seja, o modelo é executado a cada 6 minutos, totalizando 240 intervalos num dia. De acordo com Khomami & Javidi [2013], esse intervalo de tempo é curto o suficiente para cobrir a maior parte de operação dos serviços dos eletrodomésticos.

Experimentos realizados com a ferramenta *MatLab* mostram que o modelo proposto é capaz de viabilizar a programação de energia e gerenciar diversos tipos de aparelhos e demandas de cargas produzidas por várias combinações de aparelhos diferentes, proporcionando reduções significativas do consumo de energia, nos experimentos obteve-se uma redução de 25% no consumo de energia diário.

Como no trabalho anterior, Zhuang et al. [2013] contam com o auxílio de um Algoritmo Genético para propor um método de programação eficiente de consumo de energia em casas inteligentes. O objetivo é minimizar o gasto de energia elétrica e reduzir o pico médio de demanda, programando o consumo de energia dos aparelhos eletrodomésticos com base na energia gerada por fontes fotovoltaicas e eólicas. A meta é garantir a estabilidade do sistema de alimentação e segurança no fornecimento de energia.

O método proposto busca otimizar o período de início e fim da operação dos aparelhos. O Algoritmo Genético cria um conjunto de soluções para o espaço de busca, avaliando qual aparelho deve entrar em operação em um determinado intervalo de tempo, considerando os custos e o pico de demanda de energia a partir de fontes de energia da rede comercial, solar ou eólica. Uma nova programação é gerada a cada 12 minutos.

Os experimentos foram executados usando a ferramenta *MatLab* considerando dados reais coletados durante um período de 92 dias na empresa *Ameren Illinois Power Company*². Os resultados mostram que, sem a aplicação do modelo, o custo de energia elétrica média diária durante os três primeiros meses chega a 48,65 Kwh. Aplicando o modelo proposto o valor chegou a 35,97 Kwh. Portanto, a adoção de uma boa precificação combinada com o modelo de programação de energia proposto é possível reduzir o custo de energia elétrica e o pico de demanda de energia de forma eficiente.

Pallotti et al. [2013] apresentam uma estratégia baseada em Algoritmo Genético para encontrar uma programação próxima do ideal de consumo de energia para um conjunto de edifícios. Os objetivos são reduzir o pico de carga e minimizar o custo de energia com a menor interferência possível no conforto dos usuários.

A estratégia propõe uma programação para o uso dos aparelhos domésticos de acordo com o padrão de consumo dos usuários e suas restrições de conforto. Cada edifício é equipado com um controlador responsável pela coleta e a transmissão de informações de consumo e pelo envio de comandos para os aparelhos (ligar/desligar).

A ferramenta *MatLab* é usada para validar a estratégia proposta e modelar um cenário composto por 246 residências equipadas com diferentes eletrodomésticos (por exemplo, geladeira, televisão, micro-ondas, máquina de lavar roupas), totalizando 2.600 aparelhos elétricos com diferentes padrões de consumo. Os experimentos mostram que soluções razoáveis de programação podem ser obtidas a partir de 200 iterações. Os ganhos obtidos foram de até 10% do total de energia consumida, quando comparados com o mesmo cenário sem a utilização da solução proposta.

²Url de acesso ao site da empresa: <https://www.ameren.com>.

2.5. Programação Linear Inteira Mista

Programação Linear Inteira Mista (PLIM) é um modelo de otimização que utiliza sistemas de equações lineares compostos por variáveis inteiras não negativas. Um PLIM é capaz de fornecer uma representação simplificada de um problema real por meio de uma função objetivo linear, responsável por direcionar o que será minimizado ou maximizado, levando em consideração um conjunto de restrições (lineares) para limitar o espaço de busca. Esta abordagem se torna útil quando é desejável a resolução de problemas com seleção de candidatos que utilizam recursos de forma fracionada, como intervalos de tempo por exemplo. Atualmente este modelo é aplicado a uma série de problemas menos complexos, conseguindo resultados exatos quando a solução é viável [Duy et al., 2012][Agnelis et al., 2013][Goldbarg, 2005].

A seguir são abordados trabalhos que utilizam a Programação Linear Inteira Mista para auxiliar na geração de programações para consumo de energia.

Duy et al. [2012] propõem um mecanismo utilizando o algoritmo de Programação Linear Inteira Mista (PLIM) na camada de antecipação, usada para prever eventos como sobrecarga das fontes elétricas e flutuações nos preços de energia. O objetivo é determinar o melhor plano de atribuição de energia para diferentes modelos de habitação. Tais modelos são classificados de acordo com os tipos de equipamentos existentes na habitação.

Como nos trabalhos abordados anteriormente, o sistema de gerenciamento de energia considera a adequação do consumo de energia elétrica e de produção de energia para maximizar a eficiência do seu uso, levando em conta o custo de energia e conforto dos ocupantes. Assim, as programações de uso da energia são computadas pelo mecanismo de antecipação, considerando: (a) energia produzida pelo fornecedor com o custo associado pelo horário; (b) a programação de consumo de energia dos serviços permanentes, aqueles que não podem ser remanejados, como exemplos temos o serviço de refrigeração de uma geladeira que deve ficar sempre ligada e (c) a programação de energia consumida pelos serviços temporários, aqueles que podem ser movimentados para execução em qualquer horário e não possuem execução contínua, por exemplo, um serviço de uma máquina de lavar roupas.

No intuito de validar o mecanismo proposto foram realizados experimentos com o auxílio de uma ferramenta *solver* para processar os dados, a ferramenta de análise hipotética *GLKP*³. Os experimentos foram realizados considerando um período de 24 horas, no qual a energia proveniente de um fornecedor da rede de energia tem que ser compartilhada entre os diferentes aparelhos existentes na habitação, ficando por conta do mecanismo proposto a escolha das melhores soluções. Os tempos de desempenho foram considerados aceitáveis para o problema, com o uso do PLIM, bem como as reduções de custo adquiridas, resultando no geral uma economia de energia de 22%. Porém para problemas maiores os autores orientam o uso de heurísticas para atingir melhores resultados, tais como Recozimento Simulado, Busca Tabu, Algoritmo Genético e Enxame de Abelhas.

Agnētis et al. [2013] propõem um modelo de decisão para gerenciamento de energia residencial baseado na Programação Linear Inteira Mista. O objetivo é determinar uma melhor programação de consumo diário de energia considerando os critérios de custo e conforto do usuário.

Conforme mostra a Figura 2.4, o modelo considera várias fontes de geração de energia: térmica, rede da concessionária e solar. O modelo trabalha com tipos de carga variáveis, como o condicionador de ar e com cargas interruptivas, como a geladeira. O principal componente é a unidade de controle lógica que gerencia todo o sistema. O módulo de otimização calcula o esquema considerado ideal, fazendo uso de um conjunto de interfaces que lidam com os dispositivos físicos do ambiente: o controlador de clima, os aparelhos variáveis e interruptivos.

³ Disponível em <https://www.gnu.org/software/glpk/>.

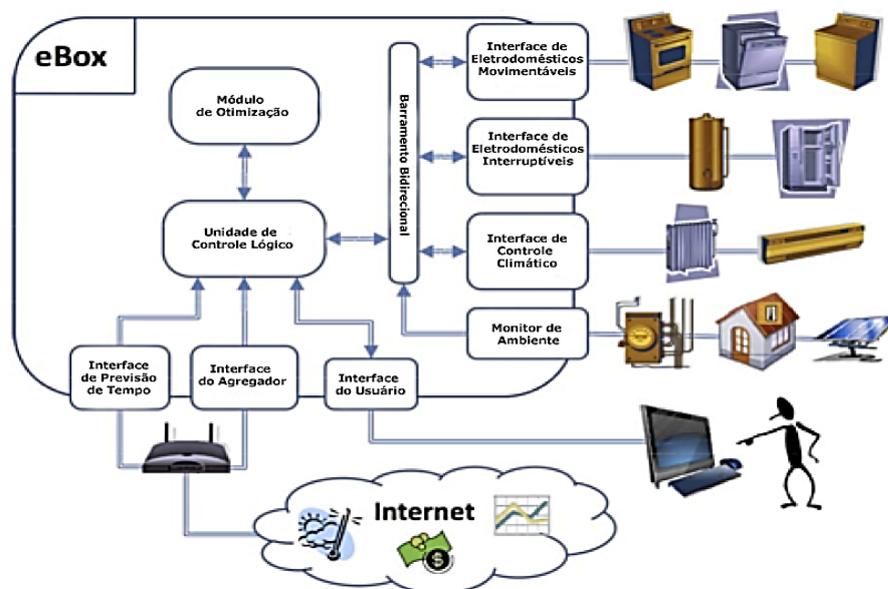


Figura 2.4. Arquitetura do modelo de decisão para gerenciamento de energia residencial baseado na Programação Linear Inteira Mista, adaptado de Agnetis et al. [2013].

Para analisar o modelo proposto foram realizados experimentos utilizando a ferramenta CPLEX. Nos experimentos, a energia consumida pelos aparelhos variou ao longo do tempo. Os resultados mostram que o modelo foi capaz de encontrar boas soluções com valores de diferença média de 6,8% em relação a ideal. De maneira geral, o tempo computacional foi considerado pequeno, e o modelo foi capaz de fornecer soluções de boa qualidade, eficazes para uma possível aplicação em casos reais.

2.6. Outras Técnicas

Nesta seção estão organizados os trabalhos com outras técnicas que tiveram menos incidência no processo de revisão sistemática, como as metaheurísticas de Enxame de Partículas Multiobjetivo, algoritmos de Janela Deslizante, Enxame de Partículas Binárias, *Shuffled Frog Leaping Algorithm - SFLA* e os métodos exatos como o caso da Programação Linear Inteira.

O algoritmo de Enxame de Partículas Multiobjetivo (EPMO) de Rui & Lingfeng [2012] foi empregado em um sistema de controle de climatização para manter o ambiente interior de um edifício com alta eficiência energética e dentro das características de conforto (conforto térmico e conforto de qualidade do ar) estipuladas pelo usuário.

O objetivo do sistema proposto é controlar e determinar a quantidade de energia necessária para cada equipamento do sistema de climatização. O método EPMO é uma melhoria do método proposto anteriormente por Rui et al. [2011], o método é embarcado no controlador do sistema de climatização para auxiliar na distribuição de energia.

O controlador do sistema de climatização com o método EPMO embutido usa informações de períodos de tempo anteriores para prever a resposta das próximas temperaturas e assim, toma as decisões adequadas, determinando a quantidade de energia enviada para cada um dos componentes do sistema de climatização que controlam as variáveis de conforto correspondentes.

Para validar o método proposto, foram simulados ambientes com temperaturas frias e quentes, num período de 24 horas. Os resultados mostram que o método proposto é capaz de minimizar o consumo de energia em até 21%, demonstrando a eficiência do método EPMO.

Beaudin et al. [2012] propõem um sistema de gerenciamento de energia residencial baseado no algoritmo de janela deslizante (do inglês, *Moving Window Algorithm - MVW*). O sistema desenvolvido busca otimizar o consumo de energia e as programações de serviços executadas considerando previsões para correções de erros na rede elétrica.

Na implementação do sistema proposto são analisados o impacto do tempo de agendamento, a periodicidade, os intervalos e as janelas de execução dos serviços. O objetivo é garantir que o agendamento de energia mantenha uma programação ideal quando atualizações periódicas dos serviços forem disponibilizadas juntamente com as previsões de consumo futuro. O sistema considera mais de uma fonte de produção de energia, provenientes da rede elétrica comercial e solar. A lista de equipamentos demandantes de energia é composta por carros elétricos, bombas d'água, aquecedores, entre outros.

Para validar o sistema proposto foram realizadas simulações considerando as informações coletadas em uma residência canadense durante o período de 24 horas. Nesse período, uma nova programação de serviços foi gerada a cada 30 minutos. Os resultados do sistema proposto são comparados com um modelo utilizando a abordagem de Programação Linear Inteira Mista (PLIM). As análises dos resultados mostram que o algoritmo de janela deslizante é mais robusto contra a previsão de erros na rede elétrica tendo cerca de 0,3% de erro, contra 16,1% do PLIM.

Barbato et al. [2011] abordam uma solução de otimização de demanda de energia que permite gerenciar o consumo diário de residências com um único usuário ou multiusuários hospedados. A solução é baseada na técnica de Programação Linear Inteira (PLI) levando em consideração diferentes fontes de energia distribuídas. Baterias são empregadas no armazenamento de energia gerada por fontes alternativas (solar) para uma posterior venda. Os objetivos finais são reduzir a conta de energia do usuário e melhorar o desempenho geral do sistema de energia elétrica.

A solução proposta é capaz de gerenciar a demanda de energia de forma otimizada e automática, tratando o consumo de energia diário dos usuários residenciais por meio da programação das atividades executadas pelos eletrodomésticos, decidindo, assim, quais os melhores intervalos de tempo para realizar o armazenamento, bem como a compra ou venda de energia para a rede elétrica.

De maneira geral, a solução foi projetada para considerar 96 intervalos de tempo de 15 minutos cada, referentes às 24 horas disponíveis num dia. Assim, os serviços são programados para serem executados em um ou mais intervalos de tempo, observando as restrições de tempo de início e término de cada atividade de acordo com o preço e o horário em que a atividade é executada. O objetivo é evitar os horários de pico, ou seja, horários nos quais há normalmente a maior concentração de eletrodomésticos funcionando simultaneamente. Uma visão geral do sistema proposto é apresentada na Figura 2.5.

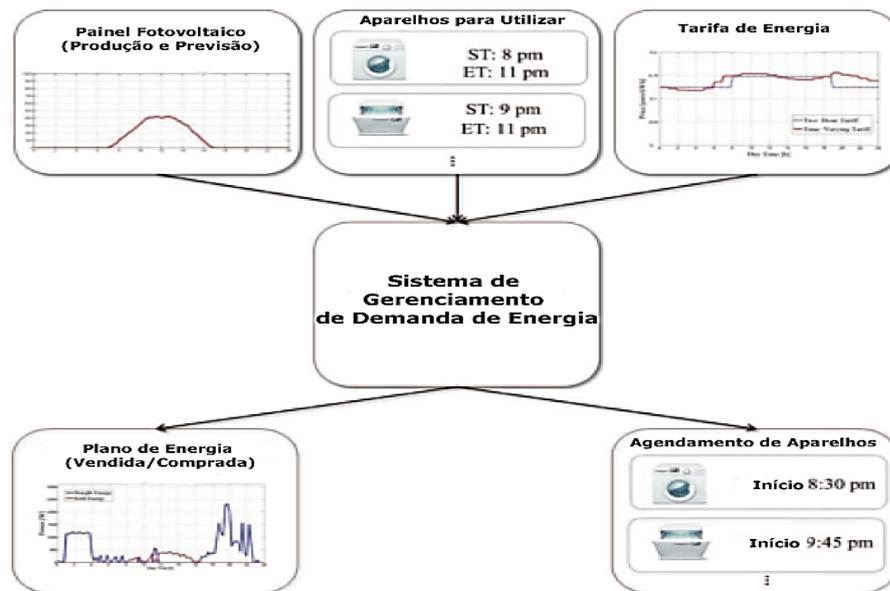


Figura 2.5. Sistema de gerenciamento de demanda de energia utilizando Programação Linear Inteira, adaptado de Barbato et al. [2011].

Os testes foram realizados visando o planejamento de melhor carga de consumo de energia, considerando cenários residenciais com único usuário e múltiplos usuários. Os dados foram coletados em ambientes reais e emulados usando a ferramenta *solver CPLEX*⁴. A solução proposta é capaz de gerenciar o uso dos aparelhos para consumir energia proveniente de fonte solar nos horários de maior custo no sistema elétrico e alternar para uso da rede concessionária no horário de menor custo. Os resultados mostram que o desempenho da solução é ligeiramente dependente da configuração de programação realizada e que atingiu uma economia de 0,11% para o cenário com único e múltiplos usuários. Os autores argumentam que para o sistema elétrico houve uma considerável melhoria, uma vez que é possível reduzir a carga de energia no horário de pico, diminuindo a sobrecarga na infraestrutura elétrica de distribuição.

Gudi et al. [2010] propõem uma ferramenta de simulação para a operação otimizada de dispositivos em residências inteligentes, baseada em um sistema de gerenciamento de demanda de energia (do inglês, *Demand-Side Management – DSM*). Um *DSM* pode ser definido como um conjunto de políticas e medidas para controlar, regular e reduzir o consumo de energia por meio de um sistema de controle. O principal objetivo da ferramenta de simulação proposta é ilustrar o

⁴ Ferramenta de otimização matemática, disponível em: <http://www01.ibm.com/software/commerce/optimization/cplex-optimizer>.

funcionamento do *DSM* orientado para o cliente e avaliar uma estimativa para o consumo doméstico de energia elétrica.

O algoritmo otimização de Enxame de Partículas binário (do inglês, *Binary Particle Swarm Optimization – BPSO*) é usado para otimizar o gerenciamento dos recursos energéticos e dos dispositivos expostos na ferramenta *DSM*.

O sistema é capaz de fazer a gestão de recursos energéticos de diferentes fontes (comercial, eólica e solar) e determinar como será feita a distribuição de energia para cada dispositivo. O sistema avalia um conjunto de aparelhos que devem estar ligados em um determinado período, bem como as restrições de custo por horário, tempo de operação, consumo de energia, prioridade e número de dispositivos. Estas informações são usadas para realizar o cálculo do consumo total dos eletrodomésticos, minimizando assim o custo do consumo de energia do cliente. A Figura 2.6 exibe a interação entre os elementos que compõem o sistema de gerenciamento de energia e o algoritmo *BPSO*.

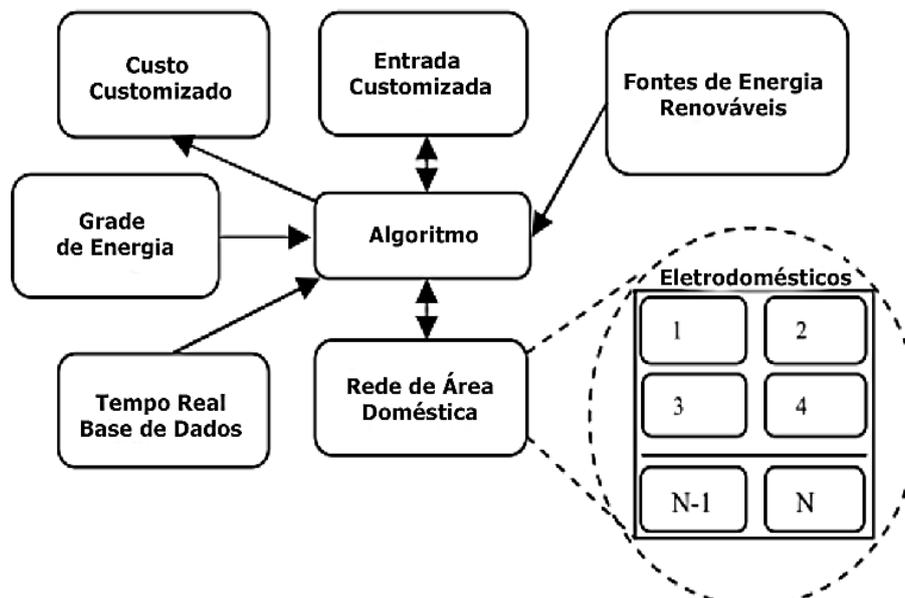


Figura 2.6. Arquitetura da ferramenta de simulação de gestão de energia usando Enxame de Partículas Binário, adaptado de Gudi et al. [2010].

A ferramenta foi avaliada considerando o consumo de energia de 10 aparelhos domésticos (máquina de lavar, secador, cafeteira, entre outros) durante um período de um dia e a utilização de fontes de recursos energéticos renováveis (solar e eólica). Foram realizados experimentos sem e

com o otimizador de recursos *BPSO*. Os resultados mostram que o emprego do *BPSO* possibilitou uma economia média de energia de 33% para o cenário avaliado.

Aqueel et al. [2013] abordam em seu trabalho o uso de técnicas de monitoração de carga não intrusiva (do inglês, *Non-Intrusive Load Monitoring – NILM*) para auxiliar os consumidores de energia doméstica a gerenciar o consumo de energia em suas casas.

Um método de balanceamento de carga de energia (*Autonomous Balancing of Load Energy – ABLE*) é proposto para dar um retorno ao usuário, motivando-os a adotarem práticas de consumo de energia mais eficientes. Uma ferramenta, desenvolvida com base nos métodos propostos, orienta os usuários com recomendações sobre o uso da energia e fornece informações sobre preço a ser cobrado em um determinado período de tempo. A ferramenta sugere ainda ações como: sugestões sobre como pagar a menor tarifa de energia proveniente da rede comercial; como usar energia durante o horário de pico ou fora do horário de pico; ou formas para agrupar e/ou programar aparelhos para serem ligados durante os períodos fora de pico.

Para validação da ferramenta, foram executados experimentos em um edifício ocupado por três pessoas durante o período de seis meses. Os resultados mostram uma economia de até 49,5% do custo, simplesmente com o deslocamento de carga para ser consumida fora do horário de pico. A ferramenta possibilitou aumentar no usuário a consciência sobre os gastos de energia na residência fazendo com que este adquira uma prática mais econômica de consumo de energia. Entretanto, apesar dos resultados promissores, os autores argumentam que o sistema ainda carece de uma inteligência maior para tratar deslocamentos automáticos e realizar os ajustes de programação dos aparelhos, conforme as restrições estabelecidas pelos usuários.

Eghbal et al. [2011] propõem um método para resolver o problema de planejamento de expansão de linhas de transmissão de rede elétrica usando o algoritmo *Shuffled Frog Leaping Algorithm - SFLA* [Eusuff et al., 2006]. O objetivo geral é minimizar o custo total para encontrar o local, o número e o tipo de novas linhas de transmissão necessárias para assegurar que o sistema de energia elétrica atenda à demanda prevista da forma mais econômica e confiável.

Para atender ao objetivo Eghbal et al. [2011] formulam o problema como um PLIM e o resolvem por meio da metaheurística *SFLA*. A prioridade na redução de carga no barramento é

modelada pela atribuição de diferentes custos da limitação de carga para cada barramento utilizado na transmissão. Assim, a quantidade de carga a ser reduzida nos barramentos deve ser menor ou igual à carga utilizada.

Para a validação do método proposto foram realizados experimentos entre o *PSO*, o *AG* e *SFLA* utilizando as ferramentas *MatLab* e *MatPower*. Uma rede com 24 barramentos com novas linhas de transmissão, parametrizações de contingência e interrupções foi considerada. O número de iterações realizadas pelos 3 algoritmos foram de 100 vezes. Nos resultados é evidenciado que o *SFLA* adquiriu um planejamento com o custo de 139 milhões de dólares, o *PSO* de 142 milhões e o *AG* de 162 milhões. Neste caso o *SFLA* e o *PSO* são melhores para resolver o problema de programação de expansão de linha de transmissão. Enquanto o *AG* apontou resultados ruins em relação ao *PSO* e ao *SFLA*.

Lee et al. [2014] projetam um algoritmo de programação de atividades para minimizar o custo de energia baseado no algoritmo *Token-bucket* [Forouzan, 2007] em sistemas de gerenciamento de energia residencial e em sistemas de gerenciamento de energia de edifício (do inglês, *Building Energy Management System – BEMS*).

A ideia é aplicar mecanismos de monitoramento para determinar o quanto de energia precisa ser alocada para cada demanda de serviço solicitada pelo usuário. A demanda do usuário depende dos fatores de satisfação e de custo. São consideradas mais de uma fonte geradora de energia: rede comercial, solar e eólica, com prioridade de uso para as fontes solar e eólica.

Para os experimentos foram realizadas simulações com dados de consumo de vários aparelhos domésticos como geladeiras, televisores, lava louça, entre outros. Nos experimentos foi verificado que o algoritmo proposto conseguiu bons resultados, incluindo tanto o consumo de energia quanto a satisfação do usuário na gerência da energia demandada, o custo evitado foi cerca de 2.100 kWh, sendo cerca de 260 kWh referente ao consumo do condicionador de ar. Os autores salientam que é necessário fazer uma combinação do padrão tarifário de acordo com cada fonte de energia, combinando a rede elétrica comercial com o sistema solar, ou da combinação da rede elétrica comercial com a energia armazenada em baterias e a energia solar para se conseguir melhores resultados.

Tudu et al. [2011] abordam o uso do Algoritmo das Abelhas (*Bees Algorithm*) em um sistema de energia híbrido com o objetivo de otimizar o uso dos recursos energéticos e minimizar os custos por meio do balanceamento do consumo da energia proveniente de várias fontes geradoras.

O algoritmo proposto considera as demandas de carga por horário e de diferentes fontes de energia (micro hidroelétrica, solar, eólica, célula de combustível, conversor, eletrolizador e tanque de hidrogênio) para realizar o dimensionamento da demanda de energia. O processo de otimização do Algoritmo das Abelhas é constituído da seguinte maneira: inicialmente, são atribuídos valores aleatórios para os módulos de geração solar e eólica para cada abelha; em seguida são calculados de hora em hora os valores de entrada para suprir a demanda de energia total e a capacidade de geração das fontes; a partir dos valores de custo líquido adquiridos ao final do processamento é possível dizer qual a melhor combinação de fontes de energia a serem escolhidas e que retorna o melhor custo de energia e o melhor custo de geração.

Para a validação do algoritmo proposto, foram realizados experimentos em uma aldeia de Kerala, na Índia, com dois cenários híbridos: hidroelétrico-solar-eólico-célula de combustível e solar-eólico-célula de combustível. O primeiro cenário obteve o custo de geração de 4.98/kWh, e o custo de energia de 7.53/kWh, enquanto que no segundo o custo de geração foi de 6.36/kWh e o custo de energia de 10.03/kWh. Diante dos dois cenários, o Algoritmo das Abelhas conseguiu tratar de maneira satisfatória o balanceamento de recursos, levando em conta uma população de 100 abelhas e um número de 100 iterações.

Um modelo de otimização e controle preditivo de temperatura é proposto por Arpaia et al. [2010], com o objetivo de minimizar o consumo de energia em um ambiente inteligente. O modelo é denominado de Enxame de Partículas Diferencial Discreta, baseado no modelo tradicional de Enxame de Partículas.

Para atender ao objetivo proposto, o modelo explora o controle de temperatura de um ambiente. O modelo de Enxame de Partículas é redesenhado para representar adequadamente uma sequência de comandos numericamente discretos. Na Figura 2.7 é mostrado o modelo de controle preditivo dividido em dois módulos principais: um modelo de envio, prevendo as próximas variáveis de estado do processo, tendo como base as variáveis já ocorridas; e um modelo inverso,

que busca otimizar uma sequência de valores de controle a partir dos dados de referência de uma determinada entrada.

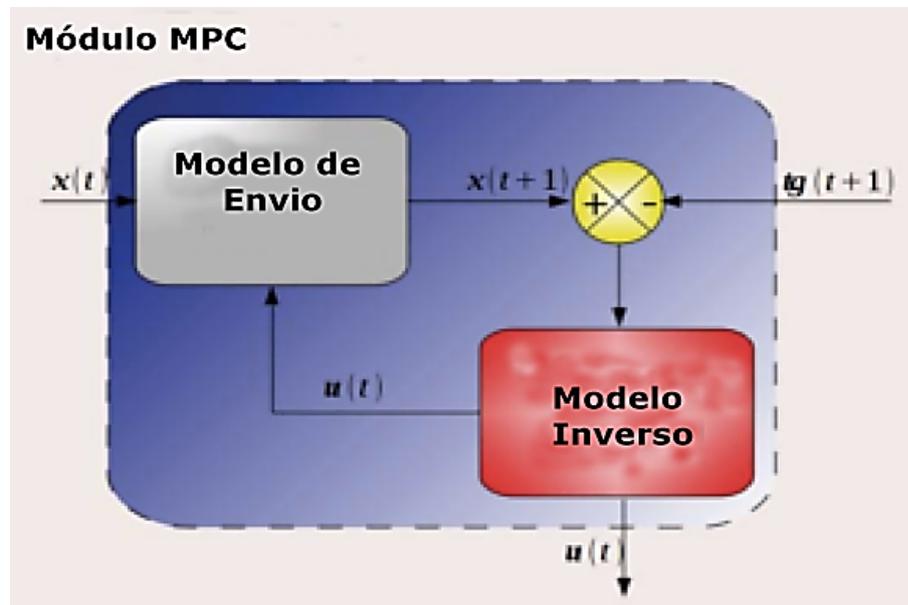


Figura 2.7. Modelo de otimização e controle preditivo de temperatura proposto com uso de Enxame de Partículas, adaptado de Arpaia et al. [2010].

Para validação do modelo proposto foram executados experimentos levando em consideração uma sala equipada com um conjunto de sensores de temperatura, coletando informações durante um período de 7 dias consecutivos. O modelo proposto foi comparado com o *PSO*, considerando um total de 500 iterações para ambos e um intervalo de previsão de 60 minutos. Os resultados mostraram que o modelo de Enxame de Partículas Diferencial Discreta proposto conseguiu melhores resultados na redução de consumo de energia e melhor desempenho quando comparado ao *PSO*, conseguindo um valor médio de consumo de 12.93 para 336.90 do *PSO*.

2.7. Considerações Finais

Este Capítulo apresentou alguns conceitos e técnicas de otimização que têm sido empregadas no desenvolvimento de soluções para minimizar custo no consumo de energia elétrica em ambientes inteligentes.

A Tabela 2.1 resume os trabalhos apresentados acima, considerando o ponto de vista das técnicas de otimização abordadas.

Tabela 2.1. Análise comparativa dos trabalhos relacionados.

Autor(es)	Ano	Técnicas					Variáveis de otimização					Previsão	Cenário				Ambiente			Fontes de Energia				Avaliação				
		Busca Tabu	Enxame de Partículas	Algoritmo Genético	PLIM	Outras	Economia(R\$)	Eficiência Energética	Ocupação	Controle de Pico	Conforto		Emissão de CO2	Consumo de Energia	Sim?	Eletrônicos em gerais	Climatização - HVAC	Iluminação	Linhas de Transmissão	Casa	Edifício	Escritório/Comercial	Rede Comercial	Eólica	Solar	Termoelétrica	Hidrelétrica	Real
Missaoui et al.	2014	✓					✓					✓	✓	✓				✓			✓							✓
Duy et al.	2012				✓							✓	✓					✓			✓							✓
Takeuchi et al.	2012	✓		✓							✓	✓	✓					✓			✓						✓	
Beaudin et al.	2012				✓	✓						✓	✓	✓				✓			✓		✓				✓	
Mangiatordi et al.	2012		✓						✓			✓	✓	✓				✓			✓						✓	
Wa et al.	2011		✓					✓				✓	✓			✓		✓			✓						✓	
Barbato et al.	2011				✓		✓		✓			✓	✓	✓				✓			✓		✓				✓	
Eunji e Hyokyung	2014			✓								✓	✓	✓				✓			✓						✓	
Rui et al.	2011		✓								✓	✓	✓	✓				✓		✓	✓	✓					✓	
Khomami e Javidi	2013			✓							✓	✓	✓	✓				✓			✓						✓	
Zhuang et al.	2013			✓			✓					✓	✓	✓				✓			✓		✓				✓	
Gudi et al.	2010					✓						✓	✓	✓				✓			✓	✓	✓				✓	
Aqeel et al.	2013					✓			✓			✓	✓	✓				✓			✓	✓	✓				✓	
Abaza e Azmy	2013		✓				✓					✓	✓	✓				✓			✓						✓	
Rui et al.	2011		✓				✓				✓	✓	✓		✓			✓			✓						✓	
Pallotti et al.	2013			✓			✓				✓	✓	✓					✓			✓						✓	
Eghbal et al.	2011		✓	✓			✓	✓				✓	✓	✓			✓				✓						✓	
Affujulla e Chauhan	2011		✓									✓	✓	✓			✓				✓						✓	
Lee et al.	2014					✓	✓					✓	✓	✓				✓			✓	✓	✓		✓		✓	
Agnetis et al.	2013				✓	✓	✓				✓	✓	✓	✓				✓			✓	✓	✓		✓		✓	
Arpaia et al.	2010		✓				✓				✓	✓	✓		✓			✓			✓						✓	
Yinliang et al.	2013		✓				✓				✓	✓	✓		✓					✓	✓						✓	
Rui et al.	2012					✓	✓				✓	✓	✓		✓			✓			✓						✓	
Tudu et al.	2011					✓	✓				✓	✓	✓		✓			✓			✓	✓	✓		✓		✓	
Jun e Kanyu	2010	✓					✓				✓	✓	✓		✓			✓			✓						✓	

Quanto ao ambiente de aplicação, a maioria das técnicas de otimização foram aplicadas em casas (ambiente residencial) [Missaoui et al., 2014][Duy et al., 2012][Mangiatordi et al., 2012][Beaudin et al., 2012][Tudu et al., 2011] e a minoria em ambientes comerciais como escritórios [Takeuchi et al., 2012][Yinliang et al., 2013][Wa et al., 2011]. Esta observação evidencia que os pesquisadores estão preocupados em atender o setor de maior crescimento e de maior consumo de energia no mundo, impulsionados pela acessibilidade de uma grande variedade de novos aparelhos elétricos.

Diferentes variáveis de otimização foram consideradas nos trabalhos analisados. Alguns trabalhos observam fatores ambientais, por exemplo, a emissão de CO2 [Takeuchi et al., 2012], como um fator de importância na tratativa de economia de energia. Outros trabalhos propõem a

construção de modelos para a previsão do consumo de energia [Missaoui et al., 2014][Duy et al., 2012] [Takeuchi et al., 2012] [Wa et al., 2011][Arpaia et al., 2010]. Um trabalho considera a ocupação do ambiente como variável determinante na abordagem de minimização de consumo de energia [Wa et al., 2011].

É importante salientar ainda o grande quantitativo de trabalhos que se utilizam de ambientes simulados para validação de suas propostas [Missaoui et al., 2014][Khomami & Javidi, 2013][Zhuang et al., 2013][Duy et al., 2012][Agnētis et al., 2013][Eunji & Hyokyung, 2014][Mangiatordi et al., 2012][Barbato et al., 2012][Eghbal et al., 2011]. Enquanto que o quantitativo de trabalhos com experimentação em cenários reais é inferior [Takeuchi et al., 2012] [Jun & Kanyu, 2010][Wa et al., 2011][Beaudin et al., 2012][Aqeel et al., 2013][Tudu et al., 2011][Arpaia et al., 2010]. Este retrato pode ser justificado pela alta complexidade para que se tenha um cenário de experimento real, sobretudo o alto custo envolvido nos aparelhos.

Entre as técnicas abordadas nos trabalhos relacionados para minimizar o consumo de energia em ambientes inteligentes, é percebido um breve destaque para a Busca Tabu [Glover & Laguna, 1997]. De acordo com Colin [2013], apesar de ser uma técnica relativamente nova quando comparada com outras metaheurísticas, ela tem encontrado resultados extremamente promissores na grande maioria das vezes, principalmente quando os problemas tratados são complexos e com um grande número de variáveis.

Por exemplo, Takeuchi et al. [2012] mostram que apesar da diferença média de execução entre a BT e AG nos seus experimentos ser apenas de 2%, a BT apresentou em 95% dos dias analisados os melhores resultados. Os autores argumentam ainda que a BT é bastante flexível, o que a torna propícia para resolver problemas complexos com bons resultados aproximados e conseguindo um bom desempenho computacional. Por estas razões, este trabalho optou pela aplicação da BT no desenvolvimento de um método para otimizar o uso de recursos em residências.

Capítulo 3

Método de Minimização de Consumo de Energia – Zippy

Este Capítulo apresenta um método criado para minimizar o custo no consumo de energia elétrica por meio da programação de serviços (ou atividades) executados em uma residência. A programação de serviço do método proposto, denominado Zippy, é baseada na metaheurística Busca Tabu.

A Seção 3.1 descreve o método proposto e o modelo de programação de serviços considerando a potência do aparelho, horário diferenciado de cobrança da tarifa de energia consumida, tempo de execução de cada serviço e o conforto em detrimento da preferência do usuário, caracterizado pela escolha de execução de determinados aparelhos a qualquer hora do dia. Uma função de custo é apresentada na modelagem do problema. A Seção 3.2 detalha a Busca Tabu proposta para otimização da programação de serviços.

3.1. Método Proposto

A busca pela eficiência energética representa atualmente um dos principais desafios dos sistemas de controle e gerenciamento de energia. Como mostrado no Capítulo 2, diferentes técnicas de otimização têm sido empregadas para otimizar o uso dos recursos existentes em ambientes residenciais como Busca Tabu [Missaoui et al., 2014][Takeuchi et al., 2012], Enxame de Partículas [Rui & Lingfeng, 2011][Wa et al., 2011] e Algoritmo Genético [Eunji & Hyokyung, 2014].

Em geral, estas técnicas visam maximizar ou minimizar alguma função de custo, levando em conta o tratamento de variáveis de otimização como quantidade de aparelhos, tarifa diferenciada por intervalos de tempos, conforto e comodidade do usuário. Tal descrição constitui-se no problema clássico de programação de serviços/horários (do inglês, *timetabling*) envolvendo

o planejamento e controle dos serviços em um tempo de duração previsto, tendo como principal objetivo a redução do custo de energia, neste trabalho é levado em conta ainda a manutenção do conforto do usuário.

Para os problemas de programações, que consideram um número grande de variáveis (problemas de alta complexidade), é comum o emprego da metaheurística Busca Tabu. Uma importante característica da BT é o fato de ser aderente a vários cenários de otimização, tornando-se parametrizável às especificidades de acordo com a natureza do problema.

Como mencionado no Capítulo 2, a Busca Tabu é uma metaheurística que possui um comportamento adaptativo, capaz de explorar um espaço de busca realizando movimentos entre uma solução e outra por meio de um comportamento próprio, fugindo de soluções ótimas locais e atingindo soluções ótimas globais ou próximas do ótimo global [Mangiatordi et al., 2012]. Como estratégia para evitar o ótimo local, o processo de busca no espaço parte de uma solução inicial e movimenta-se na vizinhança à procura de melhores resultados a cada nova iteração. As soluções correntes são armazenadas em uma lista tabu, que se constitui de uma estrutura de memória flexível para identificar os movimentos visitados em um dado período de tempo ou por um determinado número de iterações.

Este trabalho apresenta um método, denominado Zippy, criado para minimizar o consumo de energia elétrica por meio da programação de horário dos serviços executados em uma residência. O Zippy faz uso da metaheurística Busca Tabu como estratégia inteligente para fornecer uma programação para serviços executados diariamente em uma residência, como lavar roupa, passar roupa, refrigerar um ambiente e cozinhar. A função de custo proposta, modelada como um problema de Programação Linear Inteira Mista, visa minimizar o consumo de energia observando o tempo de execução de cada aparelho envolvido com o serviço, a potência elétrica dos aparelhos, o custo tarifário de energia e o nível de conforto estabelecido pelo usuário.

3.1.1. Modelo de Programação de Serviços

Descrição do Problema:

A configuração do perfil de consumo de energia dos aparelhos eletrônicos é responsável pelo aumento ou diminuição da conta de energia. Neste sentido, os aparelhos são executados em

um intervalo de tempo (t) (cinco intervalos de tempo), levando em consideração um período de 24 horas. Os intervalos de tempo representam o horário relacionado à faixa tarifária de energia: baixa, média ou alta. A tarifa é baseada no modelo de tarifa branca do setor elétrico brasileiro, aplicado tanto para os dias úteis quanto para os finais de semana. Para cada nível de tarifa é atribuído um peso Ω correspondente ao intervalo de tempo, conforme mostra a Tabela 3.1.

Tabela 3.1. Intervalo de tempo de acordo com a tarifa branca de energia.

Ω	Tarifa	Intervalo de tempo em horas(t)	Dias
1x	Baixa	0 – 18	Úteis
		0 – 24	Finais de Semana
2x	Média	18 – 19	Úteis
		22 – 23	Úteis
5x	Alta	19 – 22	Úteis

O Ω é utilizado para obter o custo tarifário de acordo com cada intervalo de tempo. Neste modelo de cobrança tarifária, a tarifa baixa possui um valor padrão (x), a tarifa média equivale a duas vezes o valor padrão ($2x$) e a alta assume o valor de cinco vezes o valor padrão ($5x$); o número de aparelho considerado para a programação é representado como A .

No modelo proposto, os aparelhos são categorizados de acordo com um intervalo de potência. Para cada intervalo, um peso w_j é atribuído ao aparelho, conforme mostrado na Tabela 3.2.

Tabela 3.2. Intervalos de potência dos aparelhos e seus respectivos pesos.

Intervalo de potência (Watts)	w_j
0 - 300	1
301 - 600	2
601 - 900	3
901 - <	4

O peso referente ao intervalo de potência w_j é usado na definição do conjunto de restrições consideradas na programação dos serviços. Por exemplo, pode existir uma restrição em

que os aparelhos dentro do intervalo de potência 601-900 *Watts* ($w_j = 3$) deverão ser executados fora do horário de pico.

A Tabela 3.3 exemplifica um conjunto de serviços a ser utilizado na programação. Por exemplo, o serviço passar roupa (serviço 1) utiliza o aparelho ferro elétrico com potência elétrica de peso 4 (ver Tabela 3.1), é executado por 83 segundos (p_j), entre os intervalos de tempo de 25981 (s_j) e 26064 (d_j) segundos.

Tabela 3.3. Possível conjunto de serviços para solução inicial.

Serviço	Aparelho	Potência (w_j)	Início (s_j)	Final (d_j)	Duração(p_j)
1	Ferro elétrico	4	25981	26064	83
2	Aspirador	4	32991	33168	177
3	Lava louça	3	70434	71556	1122
4	Cafeteira	2	0	1800	1800
5	Geladeira	1	53673	55901	2228
6	TV	1	23778	24038	260

Para uma melhor organização os serviços foram classificados em dois tipos: fixo e controláveis. O tipo de serviço fixo é aquele que envolve o uso de aparelhos que possuem características de funcionamento contínuo como as geladeiras e freezers. O serviço controlável é passível de adequações e movimentações entre os seus intervalos de tempo de funcionamentos que envolvem aparelhos como os micro-ondas, cafeteiras, aparelhos de som e TVs. Para o modelo de programação de serviços proposto não é levado em conta os serviços fixos. Logo, estes não podem ser considerados pelo critério de intervalo de tempo de preferência do usuário.

Variáveis de decisão:

O custo do perfil de energia adquirido é descrito por c_i^t , onde se tem o custo c , de um aparelho i , durante o intervalo de tempo t . A unidade de custo é representada em kWh.

As variáveis de decisão binárias são definidas para indicar se a programação será atribuída a determinado aparelho eletrônico ou não. São elas:

$$X_i^t \begin{cases} 1, & \text{se e somente se o aparelho } i, \text{ for executado dentro do intervalo de tempo } t \\ 0, & \text{caso contrário} \end{cases}$$

onde:

$$X_i^t = \in (0,1)$$

Função de custo:

O modelo proposto apresenta uma formulação de função de custo para o problema de minimização do custo no consumo de energia. Essa formulação é apresentada a seguir. Sejam:

w_j é o peso referente à potência elétrica média (Watts) dos aparelhos elétricos.

Ω é o peso referente à faixa tarifária por horário (intervalo de tempo t).

s_j é o tempo de início de cada serviço.

d_j é o tempo de término de cada serviço.

p_j é o tempo de duração de cada serviço.

i é o número de serviços/aparelhos executados.

t é o intervalo de tempo.

X_i^t variável de decisão para execução do serviço i dentro do intervalo de tempo t .

c^t é o custo de energia por serviço dentro do intervalo de tempo.

A_i^t é o número de aparelhos incluídos na programação.

Assim, a composição da função objetivo é formulada levando em conta que o custo do consumo total de energia da residência que é obtido a partir do somatório de consumo de todos os aparelhos em operação, considerando ainda a tarifa variável, conforme Tabela 3.1. Neste contexto, c^t representa custo da tarifa no intervalo de tempo t . O custo total de consumo de energia para todos os aparelhos é representado na equação 3.1:

$$\text{Minimizar } \sum_{t=1}^m c^t \sum_{i=1}^n A_i^t$$

(Equação 3.1).

Restrições:

a) Intervalo de tempo de preferência do usuário

À escolha do usuário, há aparelhos que podem ser executados em determinados intervalos de tempo, dependendo da escolha do usuário. Mesmo que isso não garanta uma redução de custo. A formulação é descrita abaixo:

$$A_i^t \leq ITPU_i^t, \quad \forall i, t \quad (\text{Equação 3.2}).$$

Onde, $ITPU_i^t$ representa o intervalo de tempo de preferência do usuário. Isto é, $ITPU_i^t = 0$, se e somente se nenhum aparelho i , puder ser executado no intervalo de tempo t .

b) Capacidade de potência máxima mensal

O Ω é responsável por qualificar o intervalo de tempo com relação ao custo tarifário no decorrer do dia, conforme mostrado na Tabela 3.2. O peso referente a potência w_j corresponde ao valor atribuído a cada aparelho em função da potência elétrica consumida, conforme mostrado na Tabela 3.1. Para definir o tempo de duração, o valor de p_j é considerado após o cálculo de diferença entre o tempo final do serviço d_j e o tempo inicial do serviço s_j , como mostrado na Tabela 3.3. A capacidade de potência máxima mensal é dada como restrição do modelo, representada pela equação 3.3.

$$\sum_{t=1}^m c^t \sum_{i=1}^n A_i^t \leq Cap, \quad \forall i, t$$

(Equação 3.3).

Onde, Cap equivale a uma constante referente ao valor limite de capacidade de potência fixada para o mês, a qual a função de custo deve se limitar.

Condições de Execução

São definidas como condições de execução:

- i. Quando o intervalo de potência do aparelho for maior que 900 *Watts* ($w_j = 4$) deverá ser executado somente no intervalo de tempo de menor custo $\Omega = 1$.
- ii. Quando o intervalo de potência do aparelho for entre 601 – 900 *Watts* ($w_j = 3$) deverá ser executado somente no intervalo de tempo de menor custo $\Omega = 1$.
- iii. Quando o intervalo de potência do aparelho for entre 301 – 600 *Watts* ($w_j = 2$), não deverá ser executado no intervalo de tempo de maior custo $\Omega = 5$.
- iv. Quando o intervalo de potência do aparelho for entre 0 – 300 *Watts* ($w_j = 1$), poderá ser executado em qualquer intervalo de tempo, $\Omega = 1$, $\Omega = 2$ ou $\Omega = 5$.

c) *Formulação do PLIM*

A partir das formulações acima, podemos descrever o modelo matemático que propõe a minimização do custo no consumo de energia elétrica residencial de forma completa, como:

Minimizar função de custo (Equação 3.1)

Sujeito as restrições (Equação 3.2) – (Equação 3.3)

Onde

$$X_i^t \in (0,1), \quad \forall i, t$$

$$A_i^t \in Z^+, \quad \forall i, t$$

Esta seção apresentou uma formulação matemática baseada na Programação Linear Inteira Mista (PLIM) para determinar o escalonamento ótimo de aparelhos eletrodomésticos que forneça o menor custo para o usuário. Para lidar com o problema de escalonamento de aparelhos considerando grandes instâncias (número de aparelhos nas residências) é proposto um algoritmo de Busca Tabu, capaz de obter soluções de alta qualidade em um curto período de tempo.

3.1.2. Busca Tabu Proposta

O processo de busca parte de uma solução inicial e movimenta-se na vizinhança à procura de melhores resultados a cada nova iteração. As soluções correntes são armazenadas em uma lista

tabu, que é utilizada para evitar que soluções conhecidas sejam verificadas novamente.

Portanto, a aquisição da solução inicial é uma fase crucial para se manter a qualidade das soluções encontradas pela Busca Tabu, pois boas soluções iniciais são essenciais para encontrar soluções globais de boa qualidade. Neste trabalho, a solução inicial é gerada utilizando um algoritmo guloso que varre um dado conjunto de serviços considerando a menor potência dos aparelhos, e os classifica atribuindo pesos para gerar a solução inicial da programação de serviços, semelhante ao mostrado na Tabela 3.3.

A Figura 3.1 mostra um diagrama da Busca Tabu proposta para otimização da programação de serviços.

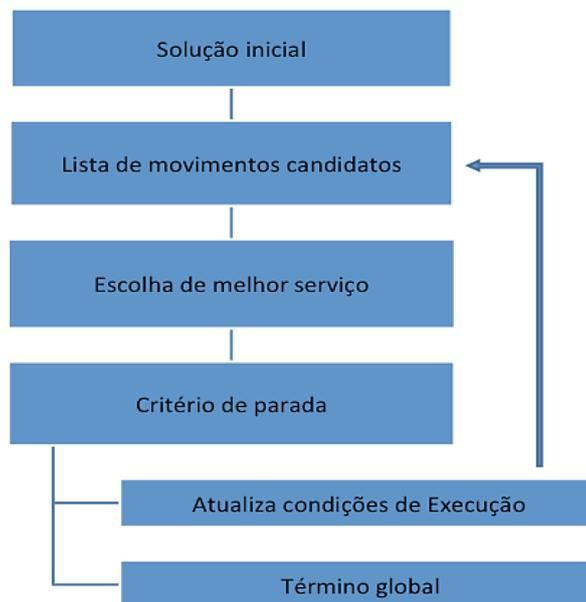


Figura 3.1. Diagrama da Busca Tabu proposta.

De posse de uma solução inicial, a etapa seguinte realiza a melhoria dessa solução adquirida. Assim, uma lista de movimentos candidatos (lista de serviços) é gerada. A lista de serviços passa por movimentos de troca, a fim de adquirir melhores resultados, gerando uma nova solução a partir da solução inicial.

Após a aquisição de uma nova solução, agora melhorada, é realizada a escolha do melhor conjunto de serviços a partir de uma busca pela vizinhança. Conforme mostra a Figura 3.2, considerando que S_i^* é a solução atual, a solução da iteração anterior representada por S_{i-1}^* pertencerá à vizinhança da solução atual. Assim, caso seja a melhor solução da vizinhança, será tomada novamente como a solução atual. Porém, para evitar a ocorrência de ciclo (loop),

uma lista de movimentos proibidos (Lista Tabu) é usada. Essa lista contém os últimos movimentos realizados na estrutura de memória de curto prazo utilizada pela Busca Tabu.

O tamanho da lista tabu é sempre um parâmetro crítico, devendo ser grande o suficiente para prevenir *looping* e pequena o bastante para não proibir os melhores movimentos adquiridos. Após vários ajustes para este parâmetro, definiu-se o tamanho ideal da lista tabu em 75% do tamanho da entrada, ou seja, tamanho variável em 75% referente ao n de aparelhos.

Para a lista tabu a estratégia é manter uma memória flexível das mudanças de movimentos específicos e recentes dentro do espaço de busca, e prevenir movimentos futuros para essas mudanças com base no histórico de movimentos ruins (aqueles que foram definidos a partir dos critérios de restrição, conforme descrito na seção 3.1.1). Assim, a Busca Tabu exclui os vizinhos que são proibidos em alguns casos, mesmo que estes sejam boas soluções da vizinhança atual.

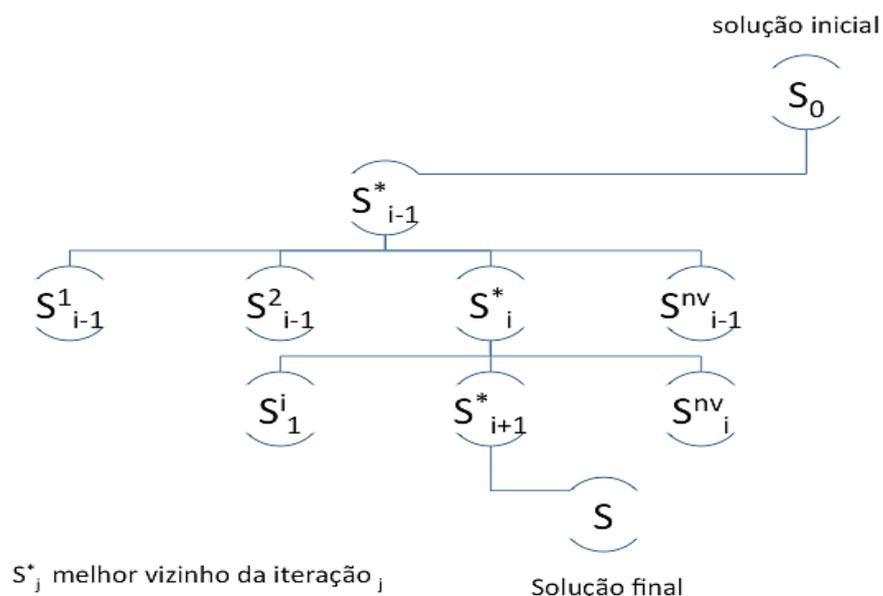


Figura 3.2. Estratégia de vizinhança para Busca Tabu, adaptada de [Glover, 1997].

Na quarta etapa é definido o critério de parada do método, aplicado sempre que um número determinado de execuções é atingido, ou ainda, caso seja encontrada a melhor solução com a programação dos serviços que garanta uma maior economicidade no consumo de energia. O critério de parada utilizado é de até 10 segundos após o encontro da melhor solução. Caso contrário, o método atualiza os critérios de restrições e refaz as etapas a partir de uma dada solução atual, gerando uma lista de movimentos candidatos e executando todo o procedimento novamente.

3.2. Considerações Finais

O Capítulo 3 apresentou o método de minimização de consumo de energia (Zippy), responsável pela geração de novas programações de execução de aparelhos eletrônicos, de forma a garantir um menor custo. Em resumo, foi descrito o seu funcionamento, o processo de aquisição da solução inicial e o procedimento da Busca Tabu proposto após o recebimento desta solução inicial.

O modelo de programação de serviços, parte integrante do método, levou em conta quatro variáveis de decisão: potência do aparelho, horário diferenciado de cobrança da tarifa de energia consumida, tempo de execução de cada serviço e conforto. Estas variáveis são diretamente afetadas pelo processo de otimização do método proposto. A solução inicial é processada e gerada primeiramente por um algoritmo guloso, e depois repassada à Busca Tabu, fato que apresenta melhores resultados e desempenho para o método.

Assim, o método Zippy pode ser inserido em sistemas de gerenciamento de energia residencial, com a finalidade de compor o módulo de otimização destes. Caso seja necessário, é possível ainda estender a integração para sistemas de automação, gerenciamento de escritório e/ou de edifícios, agregando valor como um recurso a mais de otimização de custo no consumo de energia de ambientes inteligentes.

Capítulo 4

Experimentos e Resultados

Este Capítulo descreve o cenário de experimentação e discussão de resultados experimentais realizados, de modo a permitir a avaliação da contribuição deste trabalho. O Capítulo inicia detalhando o protocolo experimental utilizado nos experimentos, incluindo a descrição do cenário, a base de dados e as métricas de avaliação. Em seguida, é mostrado em detalhes o funcionamento do método Zippy usando uma base de dados real fornecida pelo *Massachusetts Institute of Technology* (MIT).

Os resultados apresentam uma discussão em cima da aplicação do método Zippy na programação original de serviços dos aparelhos elétricos sem levar em consideração o critério de preferência do usuário e considerando a preferência do usuário.

4.1. Protocolo Experimental

4.1.1. Cenário

O cenário utilizado para validar o método Zippy foi um apartamento localizado em Massachusetts, EUA. As atividades nesse apartamento foram monitoradas 24 horas durante 16 dias. 77 sensores foram instalados em diversos locais como: fogão, armário, máquina de lavar, geladeira, portas, janelas, gavetas, micro-ondas, pias, chuveiro, tomada, lâmpadas, DVDs, aparelhos de som, lavadora de louças, cafeteira e outros. A Figura 4.1 mostra imagens de alguns dos objetos nos quais os sensores foram instalados e a Figura 4.2 mostra o mapa com a localização dos sensores no apartamento.

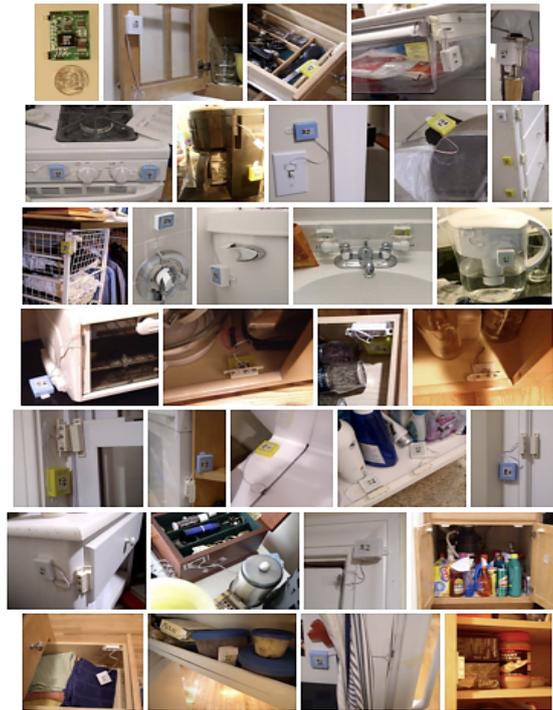


Figura 4.1. Sensores instalados no ambiente de teste [Tapia, 2003].

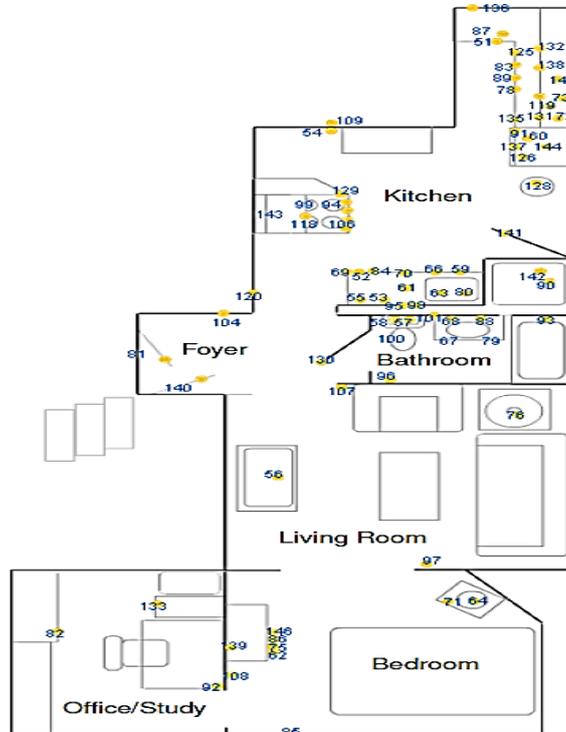


Figura 4.2. Mapa do apartamento com a disposição dos sensores e aparelhos instalados no ambiente de teste [Tapia, 2003].

A Tabela 4.1 detalha os cômodos da casa com os respectivos aparelhos alocados em cada espaço e sua quantidade equivalente.

Tabela 4.1. Dispositivos alocados por cômodo.

DISPOSITIVO	QUANTIDADE
Sala de estar	
DVD	1
Lâmpada	1
Interruptor de luz	2
Cozinha	
Micro-ondas	1
Torradeira	1
Geladeira	1
Freezer	1
Container de geladeira	3
Gaveta	7
Armário	14
Máquina de café	1
Containers	1
Bocas de Fogão	4
Forno	1
Porta	2
Coletor de lixo	1
Janela	1
Máquina de lavar roupa	1
Máquina de lavar louça	1
Interruptor de luz	2
Secador	1
Banheiro	
Descarga	1
Armário de medicamentos	2
Torneira de pia	2
Torneira de chuveiro	2
Armário	2
Gaveta	4
Porta	1
Exaustor	1
Quarto	
Lâmpada	1
Gavetas	5
Janela	1
Interruptor de luz	1
Porta-joias	1
Escritório	
Porta	1
Gaveta	2
Interruptor de luz	1
Vestuário	

Porta	1
Closet	1
Interruptor de luz	1
Varanda	
Interruptor de luz	1
TOTAL	77

O escopo do trabalho se restringe unicamente aos aparelhos elétricos que fazem uso direto de energia elétrica, comuns em residências. Desta forma, a classificação dos dispositivos considerados neste estudo é baseada na lista de aparelhos mostrados na Tabela 4.2.

Tabela 4.2. Lista de dispositivos utilizados nos experimentos.

DISPOSITIVO	QUANTIDADE
Sala de estar	
DVD	1
Lâmpada	1
Interruptor de luz	2
Cozinha	
Micro-ondas	1
Torradeira	1
Geladeira	1
Freezer	1
Máquina de café	1
Máquina de lavar roupa	1
Máquina de lavar louça	1
Interruptor de luz	2
Secador	1
Banheiro	
Exaustor	1
Quarto	
Lâmpada	1
Interruptor de luz	1
Escritório	
Interruptor de luz	1
Vestuário	
Interruptor de luz	1
Varanda	
Interruptor	1
TOTAL	20

4.1.2. Detalhamento da Base de Dados

Os dados dos sensores foram coletados e armazenados em uma base de dados disponibilizada por Tapia [2003] e Tapia et al. [2004]. A base de dados contém dados dos sensores

e das atividades realizadas pelo morador do apartamento. Os dados estão organizados da seguinte forma:

- **sensor_data:** é uma matriz que contém as informações de todos os sensores, no formato:
[year_day week_day activation deactivation interval sensor_id location type], onde:
 - **year_day:** é um número que representa o dia do ano.
 - **week_day:** é um número entre 1 e 7 que especifica o dia da semana (1 = segunda-feira, 2 = terça-feira, 3 = quarta-feira, 4 = quinta-feira, 5 = sexta-feira, 6 = sábado e 7 = domingo).
 - **activation:** representa o tempo de ativação do sensor em segundos a partir de 00:00.
 - **deactivation:** representa o tempo de desativação do sensor em segundos.
 - **interval:** representa o tempo que o sensor permaneceu ativado em segundos.
 - **sensor_id:** é um número que representa a identificação do sensor. Cada sensor tem seu próprio ID único.
 - **location:** é um número que representa a localização do sensor, quarto da casa, por exemplo.
 - **type:** é um número que representa o aparelho no qual o sensor foi instalado.
- **activities_data:** é uma matriz contendo todos os rótulos do serviço/atividade coletada, no formato:

[year_day, week_day, start_time, activity_code, indicator subcategory_index end_time], onde:

- **year_day:** é um número que representa o dia do ano.
- **week_day:** é um número entre 1 e 7 que especifica o dia da semana (1 = segunda-feira, 2 = terça-feira, 3 = quarta-feira, 4 = quinta-feira, 5 = sexta-feira, 6 = sábado e 7 = domingo).
- **start_time:** momento em que a atividade começa, em segundos.
- **end_time:** momento em que a atividade termina, em segundos.

É importante ressaltar que a base de dados do *MIT* foi alterada para conter informações sobre o consumo de energia de cada aparelho e adicionado um peso para os intervalos de potência dos aparelhos, conforme mostrado na Tabela 3.1. Tais informações foram adicionadas

com base nas especificações de fábrica de cada aparelho. Um liquidificador, por exemplo, consome cerca 300 watts/horas. A Figura 4.3 mostra o consumo (watts/horas) dos aparelhos da base.

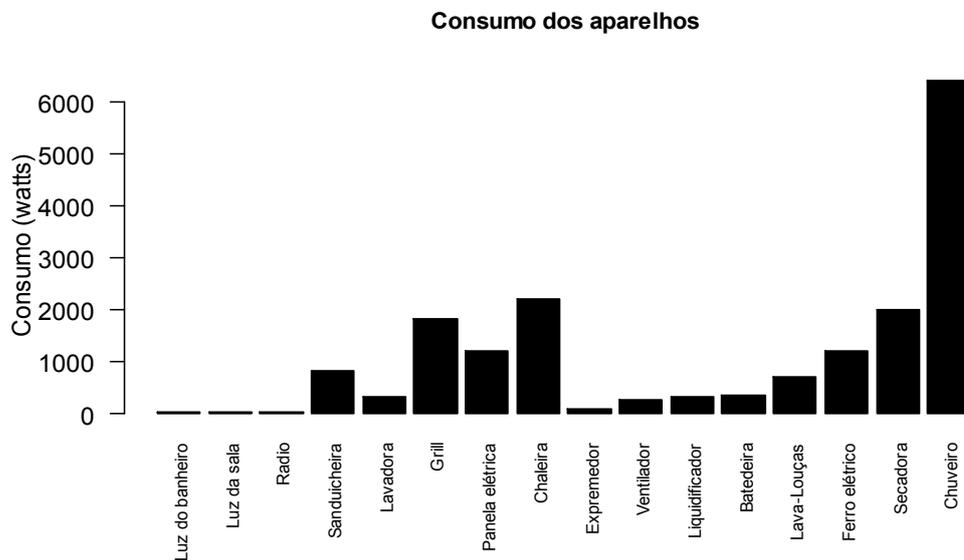


Figura 4.3. Consumo dos aparelhos elétricos em watts.

4.1.3. Hardware e Software utilizados nos Experimentos

O modelo de programação proposto foi implementado usando o *OptaPlanner* [2015] e *Jboss* [2015], um framework *open source* da *Red Hat* que reúne um conjunto de algoritmos de otimização (heurísticas e metaheurísticas) desenvolvido em linguagem Java que podem ser aplicados para resolver problemas de planejamento de maneira eficiente e escalável.

Os experimentos foram realizados em um computador com a seguinte configuração: processador 2.26 GHz Intel Core 2 Duo, 4 GB de memória RAM DDR3, placa gráfica NVIDIA GeForce 9400M 256 MB.

4.1.4. Métricas de Avaliação

Dois métricas foram selecionadas para avaliar o método Zippy: consumo de energia por serviço e o consumo de energia total diário. Estas métricas são utilizadas para avaliar o quão eficiente é o método proposto em economizar energia elétrica.

O consumo de energia por serviços é caracterizado pela duração do serviço, pela potência de cada aparelho elétrico, valor da tarifa de energia⁵ (R\$/kWh 0.32081 praticado pela concessionária Eletrobras Amazonas Energia) e pelo peso referente à tarifa variável por horário. A definição de cada variável é a mesma descrita na Seção 3.1.1, resumida aqui na equação:

$$p_j * w_j * 0.32081 * \Omega(t) = \text{consumo por serviço} \quad (\text{Equação 4.1})$$

w_j é o peso referente à potência elétrica média (Watts) dos aparelhos elétricos.

Ω é o peso referente à faixa tarifária por horário.

p_j é o tempo de duração de cada serviço.

O consumo total diário de energia é definido com base no somatório de todos os serviços no intervalo do dia, em um período de tempo de 24 horas. As referências de horário fora de ponta, intermediário e ponta, foram utilizadas conforme a Figura 4.4, sendo o horário de ponta compreendido entre as 19 horas e 22 horas.

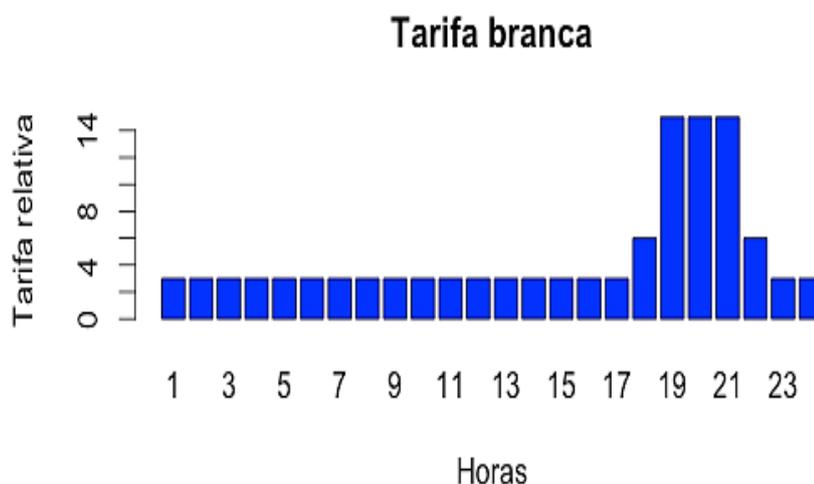


Figura 4.4. Referências de horários variados da Tarifa Branca, adaptado de [Aneel, 2010a].

4.2. Resultados

As Figuras 4.5 e 4.6 exemplificam o uso dos aparelhos em diferentes dias no apartamento monitorado. A Figura 4.5 mostra os intervalos de execução dos aparelhos elétricos no dia 27/03/2003, uma terça-feira. A figura mostra, por exemplo, que o chuveiro elétrico foi utilizado entre às 7 horas e 01 minuto e 7 horas e 16 minutos da manhã.

⁵ Valor da tarifa de energia atual, disponível em: <http://www.aneel.gov.br/aplicacoes/tarifaAplicada/index.cfm>

geradas n soluções até que seja encontrada uma melhor solução, aquela que atende os requisitos de restrições e que oferece o menor custo de energia.

Por exemplo, a Figura 4.7 representa o passo a passo do procedimento de otimização e as várias programações geradas para o dia 03/04/2003. O aparelho *dryer clothes*, na sua programação inicial, é executado no intervalo de tempo $\Omega(t) = 5$, o de maior custo (Figura 4.7a). Em seguida o método Zippy gera outras programações com diferentes sugestões de execução, como mostrado na Figura 4.7 (b), (c), (d), (e), (f), (g), sendo esta última considerada a de melhor custo. Na Figura 4.7g, o aparelho *dryer clothes* é programado para ser executado no intervalo de tempo $\Omega(t) = 1$ (g), o intervalo de tempo de menor custo considerado pela tarifa variável de energia.

Day	Time	wj1	wj2	wj3	wj4
93 Th	1	Foyer Lamp...	Coffee Pot-...		Barbecue Gr...
		Bathroom L...	Coffee Pot-...		
		Bathroom L...			
		Bathroom L...			
		Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
		Bathroom L...			
		Flat Iron-11			
		Bathroom L...			
	2	Bathroom L...	Electric Nife...		
	5	Bathroom L...			Electric Iron...
		Bathroom L...			Dryer Cloth...

(a)

Day	Time	wj1	wj2	wj3	wj4
93 Th	1	Bathroom L...	Coffee Pot-...		Barbecue Gr...
		Bathroom L...	Coffee Pot-...		Dryer Cloth...
		Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
		Bathroom L...			
		Flat Iron-11			
	2	Foyer Lamp...	Electric Nife...		Electric Iron...
		Bathroom L...			
		Bathroom L...			
	5	Bathroom L...			
		Bathroom L...			

(e)

Day	Time	wj1	wj2	wj3	wj4
93 Th	1	Foyer Lamp...	Coffee Pot-...		Barbecue Gr...
		Bathroom L...	Coffee Pot-...		
		Bathroom L...			
		Bathroom L...			
		Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
		Bathroom L...			
		Flat Iron-11			
		Bathroom L...			
	2	Bathroom L...	Electric Nife...		
	5	Bathroom L...			Electric Iron...
		Bathroom L...			Dryer Cloth...

(b)

Day	Time	wj1	wj2	wj3	wj4
93 Th	1	Bathroom L...	Electric Nife...		Barbecue Gr...
		Bathroom L...			Dryer Cloth...
		Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
		Bathroom L...			
		Flat Iron-11			
	2	Bathroom L...	Coffee Pot-...		Electric Iron...
		Bathroom L...	Coffee Pot-...		
	5	Foyer Lamp...			
		Bathroom L...			
		Bathroom L...			

(f)

Day	Time	wj1	wj2	wj3	wj4
93 Th	1	Foyer Lamp...	Coffee Pot...		Barbecue Gr...
		Bathroom L...	Coffee Pot...		
		Bathroom L...			
		Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
		Bathroom L...			
	2	Bathroom L...	Electric Nife...		Electric Iron...
		Bathroom L...			
		Flat Iron-11			
	5	Bathroom L...			Dryer Cloth...
		Bathroom L...			

(c)

Day	Time	wj1	wj2	wj3	wj4
93 Th	1	Bathroom L...	Electric Nife...		Barbecue Gr...
		Bathroom L...			Dryer Cloth...
	2	Bathroom L...	Coffee Pot...		Electric Iron...
		Foyer Lamp...	Coffee Pot...		
	5	Bathroom L...			
		Bathroom L...			
		Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
		Flat Iron-11			

(g)

Day	Time	wj1	wj2	wj3	wj4
93 Th	1	Bathroom L...	Electric Nife...		Barbecue Gr...
		Bathroom L...	Coffee Pot...		Dryer Cloth...
		Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
		Bathroom L...			
		Flat Iron-11			
	2	Bathroom L...	Coffee Pot...		Electric Iron...
		Bathroom L...			
	5	Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			

(d)

Figura 4.7. Procedimento de otimização realizado no dia 03/04/2003.

Os resultados apresentados a seguir são baseados em dois cenários. No primeiro, o método é responsável pela escolha da programação de menor custo sem qualquer interferência do usuário (método sem preferência do usuário) e, no segundo, o usuário define um conjunto de aparelhos elétricos para serem executados em um horário específico de sua preferência (método com preferência do usuário).

A Figura 4.8 ilustra a programação de uso dos aparelhos no dia 27/03/2003 (sem a utilização do método Zippy), conforme programação detalhada, apresentada na Figura 4.5. A Figura 4.8 mostra que o intervalo de tempo $\Omega(t) = 1$ possui um maior número de aparelhos elétricos de menor potência $w_j = 1$, dois aparelhos no intervalo de tempo $\Omega(t) = 2$ e um aparelho no intervalo de tempo $\Omega(t) = 5$.

Day	Time	wj1	wj2	wj3	wj4
86 Tu	1	Bathroom L...	Eletric Mixe...		Hair Dryer-...
		Foyer Lamp...			Eletric Sho...
		Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
		Bathroom L...			
		Bathroom L...			
		Bathroom L...			
		Bathroom L...			
		Eletric Fuit ...			
		Kitchen Exh...			
		Blender- 11			
	2	Bathroom L...	Dishwasher...		
5				Eletric Iron...	

Figura 4.8. Programação padrão dos serviços do dia 27/03/2003.

Então o método Zippy é aplicado para estabelecer a melhor programação que forneça um equilíbrio na distribuição dos aparelhos elétricos de acordo com o intervalo de tempo e a potência dos aparelhos. A programação resultante do método é apresentada na Figura 4.9. Na nova programação, além da distribuição do quantitativo de aparelhos de forma mais uniforme houve a realocação dos aparelhos de maior consumo (*dishwasher* e *eletric iron*) para o intervalo de menor custo, e a realocação de aparelhos para o intervalo de custo médio (*Bathroom Lamp* e *Foyer Lamp*), possibilitando uma redução no custo de energia elétrica para o dia 27/03/2003 de cerca 16% quando comparada com o modelo original, sem a aplicação do método. A melhor programação adquirida pelo método foi gerada após 131 movimentos de troca entre os aparelhos.

Day	Time	wj1	wj2	wj3	wj4
86 Tu	1	Bathroom L...	Eletric Mixe...		Eletric Iron...
		Bathroom L...	Dishwasher...		Hair Dryer-...
		Bathroom L...			Eletric Sho...
		Bathroom L...			
		Eletric Fuit ...			
		Kitchen Exh...			
		Blender- 11			
	2	Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			
	5	Bathroom L...			
		Foyer Lamp...			

Figura 4.9. Programação otimizada dos serviços sem critérios de preferência do usuário do dia 27/03/2003.

Para o cenário com preferência do usuário, foram selecionados três aparelhos (*electric fruit bowl, dishwasher, e bathroom lamp*) identificados na Figura 4.10 com a imagem de um cadeado. Estes aparelhos selecionados, não serão realocados para outro horário, em nenhuma hipótese, pois a preferência do usuário se sobrepõe a qualquer outra restrição.

Day	Time	wj1	wj2	wj3	wj4
86 Tu	1	Bathroom L...	Eletric Mixe...		Eletric Iron...
		Bathroom L...			Hair Dryer-...
		Bathroom L...			Eletric Sho...
		🔒 Eletric F...			
		Kitchen Exh...			
		Blender- 11			
		2	Foyer Lamp...	🔒 Dishwas...	
	Bathroom L...				
	🔒 Bathroo...				
	5	Bathroom L...			
		Foyer Lamp...			
		Bathroom L...			

Figura 4.10. Programação otimizada dos serviços com critérios de preferência do usuário do dia 27/03/2003.

Portanto, a programação do dia 27/03/2003, quando aplicado o método Zippy com os

critérios de preferência de usuário, resultou em uma redução no custo de consumo de energia elétrica de 11%, comparada com a programação original. Os resultados mostram que, apesar do usuário estabelecer a execução de determinados aparelhos em horários de maiores custos, ainda assim o método consegue garantir uma economicidade considerável a partir da realocação dos demais aparelhos. Ao comparar o consumo do mesmo dia com a aplicação do método sem considerar as preferências do usuário, a diferença é de 5% de menor economicidade adquirida pelo método Zippy com critérios de preferência.

A Figura 4.11 mostra um comparativo do custo total por dia, levando em conta o custo gasto com a programação original de execução dos aparelhos e com a programação gerada com a aplicação do método Zippy. No dia 02/04/2003, por exemplo, o custo de execução dos aparelhos na programação original (barra preta) foi de R\$ 8,99, enquanto que, para a programação com o método Zippy sem a preferência do usuário (barra com linhas verticais) foi de R\$ 2,03. O custo adquirido pela programação do método Zippy com a preferência do usuário (barra com linhas horizontais) se manteve semelhante ao da programação original. Isto ocorreu porque os aparelhos escolhidos como preferência do usuário não realizaram movimentações, e os demais aparelhos que foram realocados, se mantiveram no mesmo intervalo de tempo, portanto, não influenciando o custo.

Outra redução interessante no custo de energia foi apresentada no dia seguinte, 03/04/2003, onde os custos de energia foram R\$ 10,49, R\$ 2,44 e R\$ 3,03 para as programações originais, Zippy sem preferência e Zippy com preferência, respectivamente. Entretanto, no dia 10/04/2003, o custo obtido pelo método Zippy com a preferência do usuário foi superior ao custo diário da programação original. Este fato é justificado pela escolha de execução de determinados aparelhos no intervalo de tempo $\Omega = 5$, conforme preferência estabelecida pelo usuário.

Nos finais de semana (sábados e domingos) representados na Figura 4.11 pelos dias 31/03/2003, 01/04/2003, 07/04/2003 e 08/04/2003, os custos de energia não obtiveram variações para nenhuma das programações efetuadas. Isto ocorreu devido ao esquema de tarifação representado no modelo de programação adotado na lista tabu, que não considera diferenciação de valores por horário para esses dias.

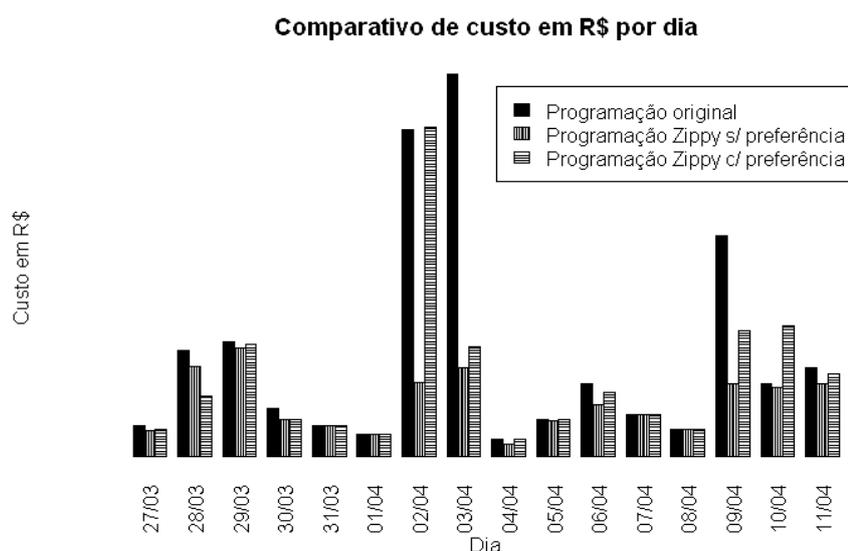


Figura 4.11. Comparativo de custo no consumo de energia durante 16 dias.

Os custos totais do consumo de energia representado pelo somatório de todos os dias considerando o custo original e os custos com a aplicação do método Zippy são apresentados na Tabela 4.3.

Tabela 4.3. Percentual de economia adquirido com a aplicação do método Zippy.

Cenário	Custo Total	Economia
Programação original	R\$ 41,80	-
Programação do método Zippy sem preferência do usuário	R\$ 22,44	46 %
Programação do método Zippy com preferência do usuário	R\$ 31,53	25 %

No geral, levando em conta o total de 16 dias, a programação original gerou um custo de R\$ 41,80; a programação aplicando o método Zippy sem o critério de preferência do usuário, gerou um custo de R\$ 22,44; e o método Zippy, com o critério de preferência do usuário, gerou um valor de R\$ 31,53. Desta forma, o método proposto foi capaz de adquirir uma economia total de 46%, quando não considera a preferência do usuário, e de 25% quando o critério de preferência do usuário é considerado.

Para validar a eficiência do método quanto ao seu desempenho, foi realizada uma análise a partir dos tamanhos variados da lista tabu, sendo os valores: 5%, 10%, 25%, 50% e 75% do tamanho da instância utilizada, seguindo uma abordagem já adotada por [Missaoui et al., 2014].

Para esses valores, a Figura 4.12 mostra que o desempenho quanto ao tempo de execução

do método Zippy, sem preferência do usuário foi em média de 209 milissegundos, e o Zippy com a preferência do usuário foi em média de 794 milissegundos, considerando um quantitativo de 5 aparelhos escolhidos como preferência do usuário.

O quantitativo de movimentos necessários para encontrar a melhor solução foi de 131, sem considerar a preferência do usuário e de 508, considerando a preferência de usuário.

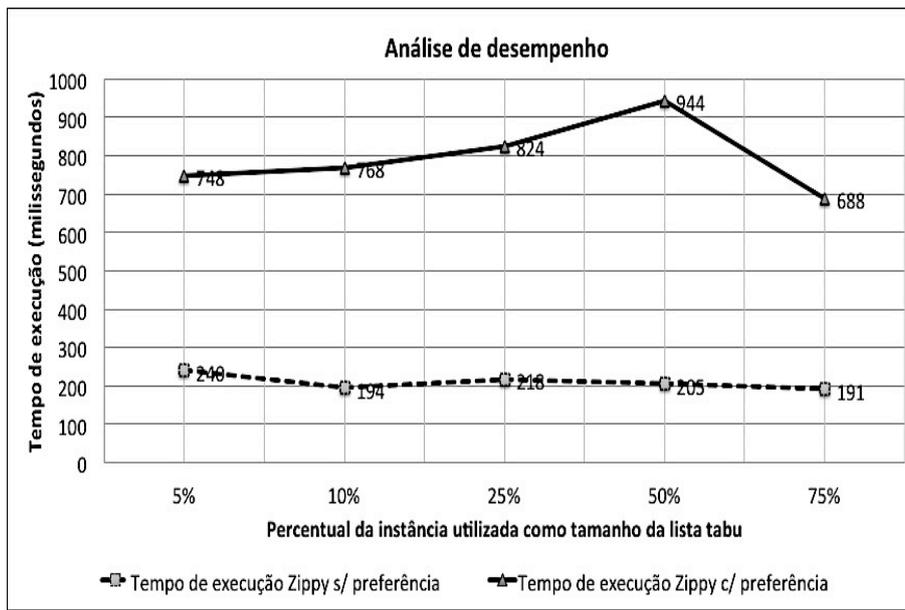


Figura 4.12. Análise de desempenho do algoritmo com diferentes parâmetros de lista tabu.

4.3. Considerações Finais

Este Capítulo descreveu o ambiente de teste utilizado para a validação do método Zippy, bem como os resultados obtidos utilizando uma base de dados que reflete um cenário real de uma residência. A realização dos experimentos nesta base foi importante para validar a aplicabilidade do Zippy em cenários similares do mundo real.

O método proposto adquiriu resultados bastante satisfatórios com variações de redução de custo de energia elétrica total entre 25% e 46%, o que demonstra a sua eficácia. Quanto à eficiência do método, foi verificado que o mesmo apresentou uma boa média de tempo de execução, sendo 209 milissegundos para o Zippy sem preferência de usuário e 794 milissegundos para o Zippy com preferência de usuário, considerando o uso de diferentes parâmetros de tamanho da Lista Tabu utilizada.

Capítulo 5

Conclusões e Trabalhos Futuros

No cenário de aumento da demanda do consumo de energia elétrica mundial e das mudanças gradativas no setor elétrico brasileiro, torna-se cada vez mais importante o conhecimento e o gerenciamento do consumo de energia elétrica em ambientes residenciais.

Com o objetivo de gerir melhor o consumo de energia elétrica residencial este trabalho apresentou um método capaz de otimizar o gerenciamento de energia elétrica em ambientes residenciais, minimizando o custo do consumo de energia, por meio da programação dos horários de execução dos aparelhos elétricos.

O modelo de programação dos horários de execução dos aparelhos proposto leva em consideração a tarifa variável da conta de energia elétrica, a qual são cobrados diferentes valores de custo por período: *i)* $\Omega(t) = 1$ para os horários de faixa de consumo original; *ii)* $\Omega(t) = 2$ para os horários de faixa de consumo médio e; *iii)* $\Omega(t) = 5$ para os horários de faixa de consumo de ponta, aquele no qual há a maior demanda e sobrecarga na rede elétrica da concessionária.

A minimização do custo de consumo de energia elétrica pelo método Zippy, baseado na metaheurística Busca Tabu, levou em consideração os fatores de potência dos aparelhos, tempo de execução dos serviços, tarifa variável por horário e a preferência do usuário por executar determinados aparelhos em um horário de sua escolha. No método proposto, os aparelhos foram categorizados de acordo com o intervalo de potência correspondente, definido em *watts*.

A variável de decisão *intervalo de tempo* representa o horário relacionado à faixa tarifária de energia: baixa, média ou alta. A tarifa é baseada no modelo de tarifa branca do setor elétrico brasileiro [Figura 4.4. Referências de horários variados da Tarifa Branca, adaptado de Aneel, 2010a]. A variável de decisão *tempo de execução* de cada serviço é usada para tratar restrições de deslocamento de serviços entre os intervalos de tempo existentes. A variável de decisão *conforto*

corresponde às preferências de horários em que cada serviço pode ser executado, conforme escolha do usuário. Contudo, para garantir os critérios de conforto estabelecidos pelo usuário, esta variável pode acarretar em restrições ao modelo de programação que não considerem o menor custo de energia.

A avaliação do Zippy foi realizada utilizando uma base de dados real. Os resultados mostraram que o método proposto é capaz de obter bons percentuais de economia de energia. No geral, os custos totais do consumo de energia considerando os dias analisados, geraram uma programação eficiente proporcionando uma economia de até 46%. Mesmo para os casos nos quais o usuário define horários para execução de alguns aparelhos a economia foi de 25%. Portanto, o método foi capaz de tratar o problema de realocação de horários de execução dos aparelhos, distribuindo-os de maneira adequada nos intervalos considerados mais viáveis, de menores custos, respeitando as restrições atribuídas.

Uma das dificuldades encontradas na execução deste projeto foi localizar bases de dados que pudessem atender às necessidades do objeto de pesquisa deste trabalho. Mesmo a base de dados do MIT, projetada inicialmente para reconhecimento de atividade, teve que ser adaptada para incluir os valores de potência dos aparelhos dispostos na residência. Vale ressaltar ainda que a maioria dos trabalhos na literatura faz uso de base de dados sintética ou simuladas.

Outra observação importante é que dos trabalhos que abordam o tema de economia de energia com uso de métodos heurísticos, a maioria não faz qualquer comparação com outros trabalhos, como mostrado na Tabela 2.1. Uma explicação para este fato pode ser a falta de detalhamento dos métodos propostos encontrados na literatura, dificultando que os mesmos possam ser replicados e usados em um estudo comparativo.

Existem várias possibilidades para estender esta pesquisa em trabalhos futuros, entre as quais se destacam:

- Avaliar o método Zippy utilizando outras bases de dados de cenários residenciais para validar a aplicabilidade do método em outras instâncias. Uma possibilidade interessante seria avaliar o método em um cenário real (ambiente instrumentado com sensores e aparelhos elétricos). Essa avaliação é necessária para fornecer maior credibilidade aos resultados encontrados neste trabalho.

- Integrar o método Zippy em um sistema de gerenciamento de energia residencial em produção a fim de consolidar a sua eficácia e analisar o seu potencial enquanto produto de mercado.
- Aperfeiçoar o método Zippy de forma a deixá-lo mais genérico, possibilitando uma melhor adequação na aplicação em diferentes cenários, comerciais, prediais de escritórios e de ambientes sociais, garantindo uma melhor flexibilidade na aplicação em diferentes ambientes.
- Incorporar ao método proposto um módulo de previsão de consumo de energia. Este módulo de previsão poderia ser baseado em técnicas de aprendizagem de máquina, responsável por realizar previsões de consumo a partir de programações originais, e do método Zippy com e sem preferência do usuário, agregando mais funcionalidades para gestão de energia ao método.
- Expandir o método para um método de programação híbrido, aproveitando as características de buscas de outras metaheurísticas, como Enxame de Partículas, Recozimento Simulado e Algoritmo Genético. Essa estratégia poderia garantir bons resultados para um cenário de maior complexidade.

Referências

ABAZA, A.; AHMED, A. M. Demand-side management-based dynamic pricing within smart grid environment. *Smart Energy Grid Engineering (SEGE), IEEE International Conference*, vol. 28, no. 30, p. 1-6, 2013.

AFFIJULLA, S.; CHAUHAN, S. Swarm intelligence solution to large scale thermal power plant Load Dispatch. *Emerging Trends in Electrical and Computer Technology (ICETECT), International Conference*, vol. 23, no. 24, p. 196-199, 2011.

AGNETIS, A.; PASCALE, G.; DETTI, P.; VICINO, A. Load Scheduling for Household Energy Consumption Optimization. *Smart Grid*, vol. 4, no. 4, p. 2364-2373, 2013.

ANEEL. *Tarifa Branca, 120/2010*. Disponível em: <<http://www.aneel.gov.br>>. 2010a.

_____. *Bandeiras Tarifárias*. Disponível em: <<http://www.aneel.gov.br>>. 2015b.

AQEEL, H.; KAZMI, M. J. O.; GREGORY, M. P. O. Energy Management in the Smart Home. *IEEE 10th International Conference on Ubiquitous Intelligence & Computing and IEEE 10th International Conference on Autonomic & Trusted Computing*, Washington, DC, USA, p. 480-486, 2013.

ARPAIA, P.; DONNARUMMA, F.; MANFREDI, S.; MANNA, C. Model predictive control strategy based on differential discrete particle swarm optimization. *Environmental Energy and Structural Monitoring Systems (EESMS), IEEE Workshop*, vol. 9, no. 9, p. 70-73, 2010.

BARBATO, A.; CAPONE, A.; CARELLO, G.; DELFANTI, M.; MERLO, M.; ZAMINGA, A. House energy demand optimization in single and multi-user scenarios. *Smart Grid Communications (SmartGridComm), IEEE International Conference*, vol. 17, no. 20, p. 345-350, 2011.

BEAUDIN, M.; ZAREIPOUR, H.; SCHELLENBERG, A. Residential energy management using a moving window algorithm. *Innovative Smart Grid Technologies (ISGT Europe), 3rd IEEE PES International Conference and Exhibition*, vol. 14, no. 17, p. 1-8, 2012.

BATTITI, R; TECCHIOLLI, G. The reactive tabu search. *ORSA Journal on Computing*, no. 6, p. 126–40, 1994.

CARLOS, L.; TERESINHA, M.; STEINER, A. *Metaheurísticas em Pesquisa Operacional*. 2013.

COLIN, E. C. *Pesquisa operacional: 170 aplicações em estratégia, finanças, logística, produção marketing e vendas*. Rio de Janeiro, LTC, p. 249, 2013.

CUNHA, R. C. Metaheurística híbrida Grassp e Busca Tabu aplicada ao problema de escalonamento. *Dissertação (Mestrado em Informática)*. Universidade Federal da Paraíba, João Pessoa-PB, 2010.

DRÉO, J.; SIARRE, P.; PÉROWSKI, A.; TAILLARD, E. Metaheuristics for Hard Optimization: methods and case studies. 2005.

DUY, L. H.; HUSSEIN, J.; STÉPHANE, P.; MIREILLE, J. An optimal approach for electrical management problem in dwellings. *Energy and Buildings*, vol. 45, 2012.

EGHBAL, M.; SAHA, T. K.; HASAN, K. N. Transmission expansion planning by meta-heuristic techniques: A comparison of Shuffled Frog Leaping Algorithm, PSO and GA. *Power and Energy Society General Meeting, IEEE*, vol. 24, no. 29, p. 1-8, 2011.

EPE. Empresa de Pesquisa Energética. Projeção da demanda de energia elétrica. Rio de Janeiro, 2012.

EUNJI, L.; HYOKYUNG, B. A genetic algorithm based power consumption scheduling in smart grid buildings. *Information Networking (ICOIN), International Conference*, vol. 10, no. 12, p. 469-474, 2014.

EUSUFF, M.; LANSEY, K.; PASHA, F. Shuffled frog-leaping algorithm: a memetic meta-heuristic for discrete optimization. *Engineering Optimization*, p. 12-154, 2006.

FILHO, A. V. Energia Elétrica no Brasil: Contexto Atual e Perspectivas. ano. 6, no. 21, 2013.

FOROUZAN, B. A. Data Communications and Networking (4th edition). *McGraw-Hill International Edition*, New York, USA, 2007.

FUJIMOTO, S. K. Estrutura De Tarifas De Energia Elétrica Análise Crítica e Proposições Metodológicas. *Tese (Doutorado)* - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Energia e Automação Elétricas. p. 195. São Paulo, 2010.

GLOVER, F. Future paths for integer programming and links to artificial intelligence. *Computers and Operations Research*, p. 533-549, 1986.

_____, F.; KOCHENBERGER, G. A. Handbook of Metaheuristics. *Kluwer Academic Publishers*, Boston, 2003.

_____, F.W.; LAGUNA, M. Tabu Search. Norwich, USA, 1997.

GOLDBARG, M. C. Otimização combinatória e programação linear: modelos e algoritmos. Rio de Janeiro, 2005.

GOLDBERG, D. E. Genetic algorithms in search, optimization and machine learning. Addison Wesley, 1989.

GUDI, N.; LINGFENG, W.; DEVABHAKTUNI, V.; DEPURU, S. Demand response simulation implementing heuristic optimization for home energy management. *North American Power Symposium (NAPS)*, vol. 26, no. 27, p. 1-6, 2010.

GUEDES, J. C. S. Manual de Tarifação da Energia Elétrica. *PROCEL - Programa Nacional de Conservação de Energia Elétrica*, 2011.

HANSEN, P. The steepest ascent mildest descent heuristic for combinatorial programming. *Congress on Numerical Methods in Combinatorial Optimization*, Capri, Italy, 1986.

HOLLAND, J. *Adaptation in natural and artificial systems*. University of Michigan Press, 1975.

KENNEDY, J.; EBERHART, R. C. Particle swarm optimization. *Conference on Neural Networks*, p. 1942–1948, 1995.

KHOMAMI, H. P.; JAVIDI, M. H. An efficient home energy management system for automated residential demand response. *Environment and Electrical Engineering (EEEIC), 13th International Conference*, vol. 1, no. 3, p. 307-312, 2013.

IEA. *Indicadores de Eficiência Energética: Essenciais para Formulação de Políticas Agência Internacional de Energia*. Disponível em: <<http://www.iea.org>>. 2014.

Jboss Community. Disponível em: <<http://docs.jboss.org>>. 2015.

JUN, Z.; KANYU, Z. Application of tabu search heuristic algorithms for the purpose of energy saving in optimal load distribution strategy for multiple chiller water units. *IEEE International Conference*, vol. 10, no. 12, p. 303-307, 2010.

LEE, S.; KWON, B.; LEE, S. Joint Energy Management System of Electric Supply and Demand in Houses and Buildings. *Power Systems, IEEE Transactions*, no. 99, p. 1-9, 2014.

LUKE, S. *Essentials of Metaheuristics*. second edition, 2013.

MANGIATORDI, E.; PALLOTTI, P.; DEL, V. F. Power consumption scheduling for residential buildings. *11th International Conference Environment Electric*, p. 926–930, 2012.

MARTINS, E. Empresa de Pesquisa Energética. *Anuário estatístico de energia elétrica 2013*. Rio de Janeiro, 2013.

MISSAOUI, R.; JOUMAA, H.; PLOIX, S.; BACHA, S. Managing energy Smart Homes according to energy prices. *Analysis of a Building Energy Management System, Energy and Buildings*, vol. 71, p. 155-167, 2014.

NASCIMENTO, F.; ARCE, J.; DIAS, A.; FILHO, A.; MIRANDA, G.; CARNIERI, C. Metaheurística otimização por enxame de partículas aplicada ao planejamento florestal. *Metaheurísticas em pesquisa operacional*, Ominipax, 2013.

Optaplanner. Disponível em: <<http://www.optaplanner.org>>. 2015.

PALLOTTI, E.; MANGIATORDI, F.; FASANO, M.; DEL, V. P. GA strategies for optimal planning of daily energy consumptions and user satisfaction in buildings. *Environment and Electrical Engineering (EEEIC), 12th International Conference*, vol. 5, no. 8, p. 440-444, 2013.

RUI, Y.; LINGFENG, W. Energy management of multi-zone buildings based on multi-agent control and particle swarm optimization. *Systems, Man, and Cybernetics (SMC), IEEE International Conference*, vol. 9, no. 12, p. 159-164, 2011.

RUI, Y.; ZHU, W.; LINGFENG, W. A heuristic economic optimizer with emission constraints for building energy management. *North American Power Symposium (NAPS)*, vol. 4, no. 6, p. 1-6, 2011.

_____, Y.; LINGFENG, W. Optimal control strategy for HVAC system in building energy management, *Transmission and Distribution Conference and Exposition (T&D)*, vol. 7, no. 10, p. 1-8, 2012.

TAKEUCHI, A; HAYASHI, T.; NOZAKI, Y.; SHIMAKAGE, T. Optimal Scheduling Using Metaheuristics for Energy Networks. *Smart Grid Conference*, vol.3, no.2, p. 968-974, 2012.

TAPIA, E. M. Activity Recognition in the Home Setting Using Simple and Ubiquitous Sensors. *M. S. Thesis Media Arts and Sciences*, Massachusetts Institute of Technology, 2003.

TAPIA, E. M.; MARMASSE, N.; INTILLE, N. S.; LARSON, K. MITes: Wireless portable sensors for studying behavior. *Extended Abstracts Ubicomp, Ubiquitous Computing*, 2004.

TOMPOS, S.; MOURATIDIS, N.; DRAAIJER, M.; FOGLAR, A.; HRASNICA, H. Enabling applicability of energy saving applications on the appliances of the home environment. *Network Conference, IEEE*, vol. 23, no. 6, p. 8-16, 2009.

TUDU, B.; MAJUMDER, S.; MANDAL, K.; CHAKRABORTY, N. Optimal unit sizing of stand-alone renewable hybrid energy system using bees algorithm. *Energy, Automation, and Signal (ICEAS), International Conference*, vol. 28, no. 30, p. 1-6, 2011.

WA, S.; OGAI, H.; HIRAI, K.; TAKAHASHI, H.; OGAWA, M. An improved PSO method for energy saving system of office lighting. *SICE Annual Conference*, vol. 13, no. 18, p. 1533-1536, 2011.

YINLIANG, X.; KUN, J.; YAN, L.; YUEBIN, Y.; WENXIN, L. Optimal building energy management using intelligent optimization. *Automation Science and Engineering (CASE), IEEE International Conference*, p. 95-99, 2013.

ZHUANG, Z.; WON, C. L.; YOAN, S.; KYUNG, B. S. An Optimal Power Scheduling Method for Demand Response in Home Energy Management System. *Smart Grid, IEEE Transactions*, vol. 4, no. 3, p. 1391-1400, 2013.