



Pós-Graduação em Ciência da Computação

HENRIQUE FIGUEIRÔA LACERDA

**RIER: Mecanismo de Recomendação
Inteligente para Uso de Equipamentos
Residenciais visando Redução do
Consumo de Energia**



Universidade Federal de Pernambuco
posgraduacao@cin.ufpe.br
www.cin.ufpe.br/~posgraduacao

RECIFE
2016

Henrique Figueirôa Lacerda

**RIER: Mecanismo de Recomendação Inteligente para Uso de Equipamentos Residenciais
visando Redução do Consumo de Energia**

Este trabalho foi apresentado à Pós-Graduação em
Ciência da Computação do Centro de Informática da
Universidade Federal de Pernambuco como requisito
parcial para obtenção do grau de Mestre Profissional
em Ciência da Computação.

**ORIENTADOR(A): Prof. Abel Guilhermino da Silva
Filho**

**CO-ORIENTADOR(A): Prof. Wellington Pinheiro
dos Santos**

RECIFE
2016

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

L131r Lacerda, Henrique Figueirôa
 RIER: mecanismo de recomendação inteligente para uso de equipamentos
 residenciais visando redução do consumo de energia / Henrique Figueirôa
 Lacerda. – 2016.
 72 f.: il., fig., tab.

 Orientador: Abel Guilhermino da Silva Filho.
 Dissertação (Mestrado) – Universidade Federal de Pernambuco. CIn,
 Ciência da Computação, Recife, 2016.
 Inclui referências.

 1. Engenharia da computação. 2. Sistemas embarcados. 3. Computação
 evolucionária. I. Silva Filho, Abel Guilhermino (orientador). II. Título.

 621.39 CDD (23. ed.) UFPE- MEI 2017-47

Henrique Figueiroa Lacerda

RIER: Mecanismo de Recomendação Inteligente para Uso de Equipamentos Residenciais visando Redução do Consumo de Energia

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação.

Aprovado em: 06/09/2016.

BANCA EXAMINADORA

Profa. Dra. Adriano Lorena Inacio de Oliveira
Centro de Informática / UFPE

Prof. Dr. Filipe Rolim Cordeiro
Departamento de Estatística e Informática / UFRPE

Prof. Dr. Abel Guilhermino da Silva Filho
Centro de Informática / UFPE
(Orientador)

Dedico este trabalho a toda minha família, amigos e professores que me deram o apoio necessário para chegar até aqui.

Agradecimentos

Primeiramente a minha família, incluindo minha mãe Laura, meu pai Jediel, minha namorada Rafaela pelo apoio fornecido durante todo o período de mestrado e principalmente na reta final durante a escrita deste trabalho. Mesmo distante, mas sempre presente, gostaria também de agradecer a minha irmã Camila.

Em seguida ao professor Abel Guilhermino por sempre acreditar no meu esforço e por todo o suporte fornecido desde a graduação até a finalização deste trabalho. Também, a toda a equipe do projeto de pesquisa que me auxiliou no desenvolvimento deste trabalho: aos professores Wellington, Adriano e Filipe e aos alunos Allan, Filipe, Vinicius e Jonathas.

Gostaria de agradecer também a todos do laboratório LINCS que me acompanharam durante todo o processo de desenvolvimento deste trabalho: professora Edna Barros e aos amigos Hugo, Bruno, Josivan, Severino, Igor, João Paulo, Pyetro, Vanessa, Jefferson, João Gabriel, João Vitor, Geyson e também àqueles que saíram do laboratório mas que nunca se afastaram: Maria, Rodrigo, Cecil, Erika e Rennason.

E, por fim, gostaria de agradecer ao CETENE/LINCS e CIn/UFPE por fornecerem todo o ambiente necessário para desenvolvimento deste projeto e escrita desta dissertação.

*If we are facing in the right direction,
all we have to do is keep on walking.*

Resumo

Com o aumento no número de equipamentos eletrônicos nas residências e o estoque cada vez menor de recursos naturais para geração de energia, cresce a necessidade de se utilizar a energia disponível de maneira mais eficiente. Os sistemas de Casas Inteligentes permitem monitorar e controlar equipamentos residenciais, além de fornecer aos usuários sugestões de utilização dos equipamentos para redução de energia. O sistema proposto neste trabalho opera no gerenciamento do consumo de energia de residências. A partir de dados de energia coletados de equipamentos domésticos, perfis de uso são identificados e aplicados a técnicas multiobjetivo em busca de novos perfis similares mas mais econômicos, fazendo um equilíbrio entre redução de energia e conforto do usuário. Neste trabalho, foi utilizado a base de dados da UK-DALE que possui dados desagregados de consumo de energia para vários equipamentos distintos. Para exploração dos parâmetros, foram realizados experimentos utilizando as técnicas multiobjetivo NSGA-II e MOPSO. Estas técnicas são bastante utilizadas na literatura por serem de simples compreensão e rápida convergência. Em seguida, para análise comparativa entre ambas, utilizou-se a métrica do hipervolume, que avalia o quão próximas as soluções estão das soluções ótimas. Os resultados obtidos fornecem liberdade ao usuário e ao sistema de recomendação permitindo sugestões de perfis mais econômicos ou mais próximos ao perfil atual. Para os melhores resultados foi possível obter conjuntos de soluções com até 70% de redução de energia.

Palavras-chave: Redução de Energia. Casas Inteligentes. Perfis de Consumo. Otimização Multiobjetivo. Problemas Multiobjetivos.

Abstract

With the growth on the number of home appliances and natural resources depletion increases the need for an efficient usage of the available energy. Smart Home systems allow you to monitor and control residential appliances, besides giving home users suggestions on how to use them focusing on saving energy. The system proposed in this work operates at the level of residential energy management and from the energy data collected from home appliances, multiobjective techniques were used to recommend equipment usage profile that is more economical than the current profiles but that are similar to these. Making a balance between energy reduction and user comfort. In this work, we used a database from UK-DALE, which contains disaggregated energy consumption data from many different appliances. For parameters exploration, experiments were done using NSGAII and MOPSO multi-objective techniques. These techniques are widely used in the literature because of their ease of use and fast convergence. For comparing their results the hypervolume metric was used, which evaluate how close the solutions are to the optimal solutions. The obtained results give the user and the recommender system the option of more economical solutions or closer to the current profile. The best obtained solutions were capable of reducing up to 70% of the current energy profile.

Keywords: Energy Consumption Reduction. Smarthomes. Load profiles. Multi-objective Optimization. Multi-objective Problems.

Lista de ilustrações

Figura 1 – Distribuição do consumo de energia das residências brasileiras.	15
Figura 2 – Processo de transformação de dados em informação úteis.	16
Figura 3 – Esquema de uma casa inteligente.	19
Figura 4 – Exemplo de Pareto front.	23
Figura 5 – Fluxo de um algoritmo evolucionário.	24
Figura 6 – Exemplo de cruzamento em dois pontos.	25
Figura 7 – Exemplo de mutação.	25
Figura 8 – Pseudocódigo NSGA-II.	26
Figura 9 – Método <i>FastNonDominatedSort</i>	27
Figura 10 – Mecanismo <i>CrowdingDistance</i>	27
Figura 11 – Pseudocódigo MOPSO.	28
Figura 12 – Pseudocódigo do Cálculo das velocidades do MOPSO discreto.	28
Figura 13 – Exemplo de como o hipervolume é calculado.	29
Figura 14 – Sistema de recomendação proposto por (SCHWEIZER et al., 2015) (Figura adaptada).	32
Figura 15 – Arquitetura do sistema utilizado por (CHAO et al., 2010).	32
Figura 16 – Arquitetura do sistema utilizado por (COTTONE et al., 2013).	33
Figura 17 – Arquitetura do sistema utilizado por (MAHMOOD et al., 2014).	34
Figura 18 – Arquitetura do sistema utilizado por (MISSAOUI et al., 2014).	35
Figura 19 – Arquitetura do sistema utilizado por (TEICH et al., 2014).	35
Figura 20 – Etapas do projeto o qual este trabalho faz parte.	36
Figura 21 – Projeto do circuito de monitoramento do consumo de energia.	37
Figura 22 – Fluxo de dados completos para recomendação de perfis de uso.	38
Figura 23 – Fluxo de operações para obter o perfil de uso do equipamento.	39
Figura 24 – Diagrama para coleta de dados dos equipamentos (KELLY, 2015).	40
Figura 25 – Periodos de monitoramento das residências da base de dados. (KELLY, 2015).	40
Figura 26 – Processo de criação do histograma semanal de uso.	44
Figura 27 – Histogramas semanais de uso de equipamentos distintos.	44
Figura 28 – Fluxo de etapas para buscar soluções baseadas nos perfis de uso.	46
Figura 29 – Exemplo de candidato a solução do problema.	47
Figura 30 – Exemplo de expansão de um candidato a solução do problema.	47
Figura 31 – Exemplo de conjunto de soluções obtido a partir da otimização multi- objetivo.	49
Figura 32 – Exemplo de solução obtido em comparação com o perfil de uso.	50

Figura 33 – Exemplo de conjunto de soluções dividido em regiões para modos de operação distintos.	51
Figura 34 – Exemplo de semanas distintas de uso do equipamento 25 (<i>lightning_circuit</i>).	52
Figura 35 – Perfil de uso encontrado do equipamento 25 (<i>lightning_circuit</i>).	53
Figura 36 – Evolução das soluções com o crescimento das gerações.	54
Figura 37 – Número de simulações e tempo de simulação com o crescimento do número de gerações.	54
Figura 38 – Convergência dos resultados com o aumento das iterações.	55
Figura 39 – Evolução das soluções com o aumento do tamanho da população para 100 gerações.	55
Figura 40 – Número de simulações e tempo de simulação com o crescimento do tamanho da população.	55
Figura 41 – Conjuntos de soluções e tempo de simulação para tamanhos de indivíduos (L) distintos.	56
Figura 42 – Soluções para o equipamento 28 (<i>subwoofer_livingroom</i>).	57
Figura 43 – Soluções para o equipamento 38 (<i>bedroom_chargers</i>).	57
Figura 44 – Comportamento das soluções com o aumento das iterações.	58
Figura 45 – Evolução do número de simulações e tempo de simulação com o aumento das iterações.	58
Figura 46 – Comportamento das soluções para cada número de partículas.	59
Figura 47 – Evolução do número de simulações e tempo de simulação com o aumento do número de partículas.	59
Figura 48 – Comportamento das soluções para partículas de tamanhos distintos.	60
Figura 49 – Evolução do tempo de simulação para diferentes tamanhos de partículas.	60
Figura 50 – Soluções do MOPSO para o equipamento 28 (<i>subwoofer_livingroom</i>).	60
Figura 51 – Soluções do MOPSO para o equipamento 38 (<i>bedroom_chargers</i>).	61
Figura 52 – Valores de hipervolume e de tempo de simulação para as duas técnicas nos equipamentos analisados.	62
Figura 53 – Perfil de Uso encontrado e Soluções obtidas pelo NSGA-II para o equipamento 3 (<i>solar_thermal_lamp</i>) e seus percentuais de redução.	63
Figura 54 – Soluções divididas em regiões e soluções selecionadas de cada região do equipamento 3 (<i>solar_thermal_lamp</i>).	64
Figura 55 – Exemplos de soluções encontradas para o eq. (<i>solar_thermal_lamp</i>).	64
Figura 56 – Percentual de redução médio ao se aplicar a abordagem a todos os equipamentos por região de conforto.	66

Lista de tabelas

Tabela 1 – Tabela comparativa dos trabalhos relacionados.	35
Tabela 2 – Equipamentos selecionados da base dados que possuem maior tempo de monitoramento.	41
Tabela 3 – Diferença de horário de leitura entre dias consecutivos devido ao intervalo médio de 6 segundos entre as coletas de dados.	42
Tabela 4 – Exemplos de expansão amostral dos dados.	43
Tabela 5 – Matriz D de distâncias entre as n semanas de uso de um equipamento.	45
Tabela 6 – Melhores parâmetros encontrados para o NSGA-II.	61
Tabela 7 – Melhores parâmetros encontrados para o MOPSO.	62
Tabela 8 – Redução de energia para soluções selecionadas do eq. (solar_thermal_lamp).	64
Tabela 9 – Reduções mínimas e máximas para cada equipamento referentes às melhores soluções encontradas.	65
Tabela 10 – Tabela comparativa dos trabalhos relacionados.	68

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivos	17
1.2	Organização da Dissertação	18
1.3	Conclusão	18
2	CONCEITOS E FUNDAMENTOS	19
2.1	Casas Inteligentes	19
2.1.1	Sensores	20
2.1.2	Atuadores	20
2.1.3	Gateway e Servidor	21
2.2	Aquisição de Dados de Energia	21
2.3	Extração de Características	22
2.4	Problemas Multiobjetivos	23
2.5	Computação Evolucionária	23
2.5.1	Algoritmos Genéticos	24
2.5.1.1	NSGA-II	25
2.5.2	Método de Enxame de Partículas - PSO	26
2.5.3	Comparação entre técnicas - Hipervolume e Testes de Hipóteses	29
2.6	Conclusão	30
3	TRABALHOS RELACIONADOS	31
3.1	Conclusão	37
4	RIER - RECOMENDAÇÃO INTELIGENTE DE UTILIZAÇÃO DE EQUIPAMENTOS RESIDENCIAIS	38
4.1	Identificação dos perfis de uso dos equipamentos	39
4.1.1	Base de dados	39
4.1.2	Separação por equipamento	41
4.1.3	Expansão da taxa de amostragem	41
4.1.4	Histograma Semanal	42
4.1.5	Extração de perfil	44
4.2	Sistema de Recomendação Multiobjetivo	45
4.2.1	Modelagem dos dados	46
4.2.1.1	Mapeamento do candidato à solução	46
4.2.1.2	Identificação dos Objetivos	47
4.2.1.3	Identificação das restrições	48

4.2.2	Otimização multiobjetivo	49
4.2.3	Recomendação de uso e modos de operação	49
4.3	Conclusão	51
5	RESULTADOS	52
5.1	Perfis de uso	52
5.2	Recomendação de Novos Perfis	53
5.2.1	NSGA-II	53
5.2.1.1	Análise do número de gerações	54
5.2.1.2	Análise do tamanho da população	55
5.2.1.3	Análise do tamanho do indivíduo L	56
5.2.1.4	Verificação dos parâmetros para outros equipamentos	56
5.2.2	MOPSO	57
5.2.2.1	Avaliação do número de iterações	57
5.2.2.2	Avaliação do número de partículas	58
5.2.2.3	Avaliação do tamanho da partícula L	59
5.2.2.4	Verificação dos parâmetros para outros equipamentos	59
5.2.3	Comparações entre as técnicas	61
5.3	RIER - Resultados para redução de Energia	62
5.3.1	Exemplo de Redução de Energia para um Equipamento	63
5.3.2	Redução de Energia para vários Equipamentos	65
5.4	Conclusão	65
6	CONCLUSÃO	67
6.1	Trabalhos Futuros	68
	REFERÊNCIAS	69

1 Introdução


Esta seção tem como objetivo inicial apresentar a motivação para a realização deste trabalho, utilizando dados e fatos atuais da literatura. Inicialmente serão comentados o aumento da quantidade de equipamentos eletrônicos nas residências, provocando o aumento do consumo de energia elétrica. Em seguida, sistemas de gerenciamento de energia residencial serão introduzidos e discutidos. Por fim, o objetivo deste trabalho é descrito.

A cada dia cresce o número de eletroeletrônicos e eletrodomésticos nos imóveis residenciais, afetando diretamente o crescimento do consumo de energia elétrica. Este aumento, além de impactar no meio ambiente, caminha em direção ao esgotamento das fontes naturais utilizadas para geração de energia elétrica, como carvão mineral e gás natural ([Agência Nacional de Energia Elétrica, 2014](#)). Com a escassez cada vez maior dos combustíveis fósseis, é crescente a necessidade de se utilizar energia elétrica de forma eficiente e sustentável ([World Trade Organization, 2010](#)). Do mesmo modo, residências representam uma parte considerável do consumo energético no mundo todo, sendo esperado um crescimento de 48% no consumo de energia residencial de 2012 até 2040 ([U.S. Energy Information Administration, 2016](#)).

A figura 1 mostra que apesar da redução no uso de lenha e carvão vegetal e nos pequenos aumentos no uso de energia para refrigeração (condicionamento ambiental), a variação mais significativa foi no uso cativo da eletricidade. Este grupo envolve todos os eletrodomésticos de uso regular (geladeira, televisão, etc.), além de lâmpadas. Em 2005, os eletrodomésticos eram responsáveis por 24% do consumo energético doméstico (uso cativo da eletricidade). Já em 2010, essa parcela representava 30% do consumo total das residências. Isso mostra que mesmo com incentivos para produção e aquisição de equipamentos domésticos mais eficientes, o crescente número de equipamentos ainda é um fator importante para o grande consumo energético residencial ([Empresa de Pesquisa Energética \(EPE\), 2014](#)).

Em ambientes residenciais, os aparelhos estão cada vez mais sendo substituídos por aparelhos eficientes que são capazes de utilizar a energia elétrica de maneira mais efetiva. Diversos programas do governo incentivam esta troca, provendo até bônus nas contas de energia ([Agência Nacional de Energia Elétrica, 2015](#)). Entretanto, boa parte do consumo residencial depende de como os moradores da residência utilizam os equipamentos. Se não há um incentivo para utilização eficiente dos equipamentos, como evitar esquecê-los ligados, a redução do consumo de energia não será tão eficaz ([VAZQUEZ; KASTNER; REINISCH, 2011](#)).

Figura 1 – Distribuição do consumo de energia das residências. Fonte: (Agência Nacional de Energia Elétrica, 2014)



Sistemas baseados em *SmartHome*, podem controlar e monitorar de forma automática, aparelhos instalados em uma residência. Desse modo, podem incentivar hábitos eficientes aos usuários de uma residência, gerenciando como a energia de uma residência é utilizada. Este tipo de sistema geralmente coleta informações sobre os equipamentos residenciais e os hábitos dos moradores da residência e altera ou sugere alterações no modo de utilização para garantia de um uso mais eficiente visando a redução do consumo e desperdício de energia.


Para aprender sobre os hábitos dos moradores e sobre os equipamentos e poder sugerir ou realizar ações, este tipo de sistema tem permitido a criação de diversas técnicas baseadas em Inteligência Computacional (SHAIKH et al., 2014). Ao permitir que esse tipo de sistema gerencie e até controle o funcionamento dos equipamentos domésticos, é também desejável que o sistema não seja tão intrusivo ao ponto de alterar a maneira com que o usuário usa o equipamento e assim preservar o seu conforto. Um dos grandes fatores que afetam a aceitação de sistemas de gerenciamento de energia residenciais é como ele vai interferir no modo de vida dos usuários da residência. O conforto do usuário é uma medida importante que deve ser levada em consideração tanto para sistemas de gerenciamento e controle de consumo de energia residenciais como para sistemas de recomendação. Normalmente quando o sistema de gerenciamento de energia resolve atuar (como ligar ou desligar algum equipamento) pode acabar retirando o usuário da sua zona de conforto. Assim, chega-se então ao problema de como gerenciar o consumo de energia da residência levando-se em consideração o conforto do usuário (LI et al., 2011).

Para permitir o funcionamento desse tipo de sistema, sensores e atuadores são utilizados para permitir a captação de informações acerca do funcionamento e/ou consumo dos equipamentos domésticos. Essas informações são armazenadas em bases de dados para serem processadas e utilizadas nos sistemas acima citados (GANZ et al., 2015).

Geralmente sensores são introduzidos entre os equipamentos e as tomadas elétricas, para permitir a captação de dados sobre o consumo e para permitir o controle do equipamento. Além disso, podem ser usados sensores de temperatura, luminosidade, entre outros para aquisição de dados. Essas informações são enviadas para algum servidor ou *gateway* que irá agrupar e armazenar as informações. Os sistemas inteligentes utilizados nestas arquiteturas, devem ser capazes de processar os dados adquiridos, extraíndo informações relevantes e descartando o que não for ser utilizado. Além disso, devem ter capacidade de lidar com grandes quantidades de dados, pois geralmente a taxa de amostragem utilizada para monitorar os equipamentos é alta, gerando uma grande quantidade de informações de utilização dos equipamentos a cada segundo.

(GANZ et al., 2015) propõe um passo-a-passo utilizado para transformar dados brutos coletados por sensores em informações úteis para um sistema. A figura 2 demonstra os estados desse fluxo descrito a seguir.

Figura 2 – Processo de transformação de dados em informação úteis. Fonte: book2008, doi = 10.1007/978-1-84800-382-8, url = <http://dx.doi.org/10.1007/978-1-84800-382-8>, year = 2008, publisher = Springer Nature, title = Multi-objective Management in Freight Logistics Ganz2015



1. **Pré-processamento dos dados.** Inicialmente, propõe-se um pré-processamento para filtragem e redução de ruídos que pode ser realizado no próprio dispositivo que possui o sensor, para descarte de informações que não serão utilizadas e, assim, diminuir custos de transmissão.
2. **Redução da dimensionalidade.** Para lidar com grande quantidades de dados que devem ser processados e armazenados (geralmente de vários sensores coletados em pequenos espaços de tempo), técnicas de redução de dimensionalidade podem ser aplicadas para reduzir o tamanho dos dados aplicando diferentes métodos aos dados, mantendo as principais características e padrões.
3. **Extração das características.** Depois, técnicas e/ou algoritmos de extração de características são aplicadas para extração e seleção das informações que serão úteis para o sistema. Trata-se basicamente da redução dos dados àquelas informações que os representarão, tal como um modelo ou uma média, por exemplo.

4. **Abstração/Inferência.** Pode-se também aplicar técnicas de abstração que inferem informações importantes a partir das características selecionadas.
5. **Representação semântica dos dados.** Por fim, tem-se uma representação semântica dos dados que poderá ser utilizada como entrada para algum sistema de decisão ou recomendação.

Assim, este processo pode ser aplicado a dados de consumo de energia coletados de uma residência. Características podem ser extraídas dos dados e assim informações de uso do equipamento podem ser obtidas para aplicação à técnicas de otimização. Do mesmo modo, é interessante extrair perfis de uso dos equipamentos e/ou dos hábitos dos moradores da residência com o intuito de poder prever comportamentos futuros ou poder sugerir ações futuras baseadas nos hábitos passados. Desta forma, utilizando informações passadas para previsões, o impacto no conforto do usuário é minimizado.

1.1 Objetivos

Este trabalho faz parte de um projeto maior, cuja proposta visa desenvolver um sistema de controle residencial baseado em Internet das Coisas e inteligência computacional, que seja capaz de reduzir o consumo energético sem afetar de forma abrupta o conforto do consumidor. Como será demonstrado adiante, um outro trabalho do mesmo grupo de pesquisa desenvolveu a parte inicial do projeto, cujo objetivo é a captação e pré-processamento dos dados de consumo de energia dos equipamentos de uma residência. Assim, o trabalho proposto nesta dissertação propõe a segunda etapa do projeto, onde a inteligência é aplicada aos dados coletados.

Assim, este trabalho tem como objetivo geral reduzir o consumo de energia residencial recomendando perfis de utilização de equipamentos a partir de dados de consumo coletados dos equipamentos, sem afetar o conforto do usuário. Para isto, inicialmente, através de dados de consumo de energia individuais de equipamentos domésticos, foi utilizada uma técnica para identificação de padrões de perfis de uso destes equipamentos. Em seguida, estes perfis foram modelados e aplicados a técnicas de otimização multiobjetivo em busca de novos possíveis perfis de uso para serem recomendados que reduzissem a utilização do equipamento sem se afastar do perfil de uso atual do equipamento, preservando o conforto do usuário.

Diferentemente de trabalhos propostos na literatura, este trabalho propõe uma redução do consumo de energia ao se aplicar diretamente a técnica aos dados colhidos dos equipamentos, fornecendo a liberdade de escolha ao usuário entre soluções mais críticas ou mais econômicas para visando reduzir o impacto no seu conforto.

1.2 Organização da Dissertação

Este trabalho é estruturado como descrito a seguir. Inicialmente na seção 2 serão fundamentados alguns conceitos básicos necessários para entendimento deste trabalho, além das técnicas utilizadas. Na seção 3 serão comentados trabalhos da literatura relacionados à mesma ideia proposta por este trabalho. Em seguida, na seção 4, será descrita toda a técnica proposta e suas etapas. Depois, na seção 4, os resultados obtidas pelo desenvolvimento dessa técnica serão mostrados e abordados, começando pela extração de perfis, passando pelos resultados de cada técnica e finalizando na redução de energia. Por fim, na seção 5, serão feitas as considerações finais deste trabalho e algumas proposições de trabalhos futuros.

1.3 Conclusão

Nesta seção foram apresentados dados motivacionais iniciais para realização deste trabalho. Em seguida, conceitos básicos de sistemas de gerenciamento em residências foram comentados, finalizando por uma breve discussão do objetivo e organização deste trabalho de dissertação.


2 Conceitos e Fundamentos

Nesta seção serão abordados conceitos e terminologias necessários para a ampla compreensão deste trabalho de dissertação. Inicialmente serão fundamentados os conceitos de casa inteligente e os dispositivos utilizados nestas para captação de informações. Em seguida serão descritas as técnicas utilizadas para extração de características dos dados. Depois, algoritmos inteligentes multiobjetivos serão explicados para, por fim, as técnicas utilizadas para redução de energia serem detalhadas.

2.1 Casas Inteligentes

Uma casa é dita inteligente quando seus equipamentos eletrônicos (incluindo iluminação, temperatura, etc.) são interconectados para permitir monitoramento e controle (KIM et al., 2014). Sistemas atuais incluem algum tipo de rede doméstica e de sensores para captação de informações sobre o uso dos equipamentos que podem ser armazenadas e, com a utilização de algum sistema inteligente, pode prover ao usuário diversas funcionalidades, como recomendação de uso para redução do consumo de energia. A figura 3 ilustra os principais componentes de um sistema de gerenciamento de energia residencial que serão descritos a seguir.

Figura 3 – Esquema de uma casa inteligente. (ZHOU et al., 2016)



2.1.1 Sensores

Em uma residência inteligente existem diversos tipos de sensores com funcionalidades distintas. Basicamente possuem o objetivo de captar dados do ambiente e enviá-los a um servidor que armazenará as informações para uso futuro. Medidores de consumo são utilizados para aferição de dados de consumo de equipamentos domésticos. Geralmente lêem dados como potência ativa e reativa, corrente, tensão, entre outros, em intervalos de tempo pré-definidos e os armazenam internamente para em seguida enviá-los a algum servidor. São um dos principais dispositivos de casas inteligentes por permitirem que o usuário monitore e acompanhe o consumo dos equipamentos da residência. Ademais, permitem que outros sistemas agregados à residência utilizem os dados de consumo para diversas funcionalidades como controle inteligente dos equipamentos, detecção de anomalias ou consumo inesperado por um equipamento.

Outros tipos de sensores incluem sensores de presença, temperatura, luminosidade, entre outros. O sensor de presença é um dos sensores mais utilizados nos ambientes residenciais. Geralmente é utilizado para detectar a presença humana em um ambiente e adequar o ambiente à sua presença ou ausência. Na sua presença pode ligar as luzes e refrigerar o ambiente, por exemplo, e na sua ausência pode desligar estes equipamentos e outros que o sistema acredite necessário. Por outro lado também pode ser utilizado como dispositivo de segurança para identificação de movimentos e indivíduos inesperados e assim, o sistema pode notificar o proprietário da residência. Sensores de temperatura são utilizados para aferição da temperatura tanto de um ambiente interno como externo. Sistemas inteligentes utilizam esses dados de temperatura para atuação ou recomendação no sistema de refrigeração da residência. Outros tipos de sensores incluem câmeras, para aprimorar o funcionamento de sensores de presença, sensores de luminosidade, para permitir um controle inteligente das luzes da residência, entre outros sensores.

Atualmente, diversas bases de dados vêm sendo criadas com dados de sensores residenciais para permitir simulação e comparação de sistemas inteligentes de gerenciamento residencial.

2.1.2 Atuadores

Um dos diferenciais de uma casa inteligente é o fato da residência permitir o controle remoto ou o autocontrole por parte de algum sistema inteligente. Assim, faz-se necessária a presença de dispositivos que possibilitem o ligamento, desligamento e até a personalização dos equipamentos domésticos. Dispositivos utilizando relés ou até infravermelho, por exemplo, vêm sendo propostos (HAN; CHOI; LEE, 2011). Através dos dispositivos que são acoplados ao equipamento eletrônico (à sua tomada), comandos são enviados remotamente e controlador liga-o ou desliga-o. Desse modo, sistemas inteligentes aplicado à casas inteligentes podem controlar equipamentos residenciais remotamente

apenas enviando comandos de desligamento ao dispositivo responsável pelo equipamento. Além disso, o sistema pode dar a opção ao usuário de enviar voluntariamente algum comando de controle ao dispositivo.

2.1.3 Gateway e Servidor

Gateway geralmente é um tipo de dispositivo que é responsável identificar rotas e endereços de dispositivos ao se enviar mensagens de controle e responsável por agrupar as informações recebidas dos dispositivos, na etapa de monitoramento. A depender do sistema e do número e disposição dos dispositivos numa residência, pode-se haver a necessidade de adição de mais de um *gateway*.

Um servidor é um dos elementos principais de um sistema de gerenciamento de energia, responsável por armazenar todos os dados e informações de monitoramento e controle do sistema. Além disso, provê a interface entre o sistema residencial e a nuvem, permitindo tanto armazenar os dados da residência em algum servidor remoto, como permitindo que o sistema residencial seja controlado à distância, através da internet. Estes servidores também são responsáveis por executar todas as etapas dos sistemas inteligentes, aplicando-os aos dados recebidos e controlando os dispositivos, em caso de atuação do sistema.

2.2 Aquisição de Dados de Energia

Atualmente, para captação de dados são usados sensores de corrente e sensores de potência. Para utilização em sistemas de gerenciamento de residências, o ideal é que se tenha a desagregação do consumo dos equipamentos individuais. Desse modo, tem-se informações relativas ao consumo de cada equipamento individualmente e, além disso, à cada informação devem estar atreladas o horário e o respectivo equipamento. Geralmente tem-se um servidor que recebe os dados provenientes dos sensores e os armazena para em seguida ser utilizado por outros sistemas. No mercado atualmente existem diversos equipamentos que permitem captação e transmissão dessas informações para o servidor utilizando diversos tipos de tecnologias distintas, como Wi-fi, *ZigBee*, *Powerline*, entre outros. Esses equipamentos são anexados aos equipamentos domésticos e colocados entre os *plugs* e as tomadas elétricas. Por exemplo, (YANG et al., 2015) utiliza sensores e um *gateway* via rede Wi-fi para captação e armazenamento de informações sobre o consumo de água de uma residência. (ZHANG et al., 2012) propõe o uso de uma rede *ZigBee* para comunicação entre sensores de informações e servidores. Por outro lado, tem sistemas como o proposto por (KELLY; KNOTTENBELT, 2015) que propõem um esquema próprio de sistema para leitura das informações do equipamento. Desse modo, o sistema pode ficar mais personalizável, além de poder adicionar outras funcionalidades.

2.3 Extração de Características

Como a captação de dados referentes aos equipamentos domésticos geralmente é feita com uma alta taxa de amostragem, isso resulta em uma grande base de dados, com diversas informações repetidas e referentes a uma grande quantidade de equipamentos. Desse modo, é interessante o uso de alguma técnica ou abordagem que permita reduzir a quantidade de dados, resultando em uma base de menor dimensionalidade mas que não deixe de representar a base inicial. Do mesmo modo, estas técnicas permitem que dados atípicos, em inglês *outliers*, não afetem o conjunto de dados, já que são dados que não representam a maioria dos dados e não devem ser inferidos como características principais (HALL; LLINAS, 1997) e (HODGE; AUSTIN, 2004).

Técnicas de agrupamento permitem agrupar dados que compartilham as mesmas características. Esse tipo de técnica utiliza a distância entre as instâncias para indicar a similaridade entre as mesmas. A distância Euclidiana é um exemplo de distância que pode ser utilizada para cálculo de similaridade. Uma das técnicas utilizadas para agrupamento, é o *K-means* (HARTIGAN; WONG, 1979). O *K-means* separa os dados em K grupos a partir da distância entre eles. A base deste algoritmo é o cálculo do chamado centroide, uma amostra que possui a menor distância para todas as outras amostras do seu grupo. O algoritmo do *K-means* é demonstrado abaixo:

Sejam $X = \{x_1, x_2, x_3, \dots, x_n\}$ o conjunto de amostras e $V = \{v_1, v_2, v_3, \dots, v_k\}$ o conjunto de centroides:


1. Selecione aleatoriamente os k centroides.
2. Atribua cada amostra x ao grupo que possui a menor distância entre o respectivo centroide v e a amostra. Sendo a distância (Euclidiana) calculada: $J = \|x - v\|^2$
3. Quando todos n pontos forem atribuídos a grupos, recalcule os k centroides.
4. Repita os passos 2 e 3 até os centroides não mudarem mais. Isso produzirá uma separação de objetos em grupos.

Este algoritmo tem a vantagem de ser um algoritmo rápido e robusto. A sua etapa de encontrar o centroide é interessante por ser uma etapa rápida que encontra uma amostra que represente aquele conjunto de amostras. Através apenas do cálculo da distância Euclidiana entre um conjunto de amostras pode-se encontrar uma amostra que seja mais próxima de todas as outras amostras.

2.4 Problemas Multiobjetivos

Um problema é dito multiobjetivo quando possui mais de um objetivo a ser otimizado e estes são conflitantes entre si. Então, seja $F(x) = \{f_1(x), f_2(x), f_3(x), \dots, f_n(x)\}$ o conjunto de n funções de objetivo (ou custo) do problema que se deseja otimizar. Ao se tentar otimizar ou reduzir cada função, poderá resultar num aumento em pelo menos uma das outras funções. A otimização multiobjetivo é definida como encontrar uma solução que minimize o valor de $F(x)$. Como $F(x)$ é um vetor e as funções competem entre si, não existe uma solução única que possa minimizar todas as funções. Desse modo, encontra-se um conjunto de soluções que são concorrentes entre si, ou seja, uma solução não é melhor que a outra em todos os objetivos simultaneamente (MULTI-OBJECTIVE..., 2008). Este conjunto é definido como *Pareto front* e é demonstrado na figura 31. Para avaliar o potencial de cada solução, aplica-se uma Função de Aptidão (do inglês, *Fitness Function*) a cada solução para saber como cada solução se comporta frente aos objetivos. Na figura, vê-se dois exemplos de soluções $\hat{x}$ e $\tilde{x}$ cujas avaliações da função de aptidão resultaram no *Pareto* da figura. É possível notar que a solução $\tilde{x}$ supera solução $\hat{x}$ com relação à função objetivo f_1 enquanto que a solução $\hat{x}$ supera a solução $\tilde{x}$ em relação a função f_2 . Desse modo, diz-se na área de computação evolucionária que são soluções não-dominadas entre si, pois uma solução não supera a outra em todos os objetivos simultaneamente.

Figura 4 – Exemplo de Pareto front. (MULTI-OBJECTIVE..., 2008)




2.5 Computação Evolucionária

Computação Evolucionária é uma área de computação que se baseia nas teorias da evolução de Darwin para definir seus algoritmos (SERRANO; CASTILLO, 2011). Estes são chamados de Algoritmos Evolucionários. Geralmente são utilizados para resolver problemas de otimização, onde o espaço de busca é amplo e custoso para se encontrar soluções boas

utilizando buscas exaustivas, como os problemas multiobjetivos já descritos. São técnicas de simples implementação e geralmente proveem boas soluções adequadas.

A figura 5 indica o fluxo de um algoritmo evolucionário. O algoritmo se baseia no conceito de um indivíduo que é uma representação do espaço de busca do problema a ser resolvido, sendo cada indivíduo uma possível solução encontrada. O conjunto de indivíduos, ou a população, é gerada, inicialmente, aleatoriamente. Em seguida, é aplicada uma técnica de seleção à população para separar algumas amostras. Esta seleção se baseia na avaliação da função de aptidão que define quão boa aquela solução é com relação às funções objetivo. As melhores amostras são selecionadas e são utilizadas para reprodução pois sua combinação pode resultar em novas boas amostras. Estas novas amostras são então avaliadas e após o cálculo da sua função de aptidão são comparadas com a população atual e as melhores amostras iniciarão a próxima iteração do algoritmo como a nova população (GROSAN; ABRAHAM, 2007).

Figura 5 – Fluxo de um algoritmo evolucionário. (GROSAN; ABRAHAM, 2007)




2.5.1 Algoritmos Genéticos

Algoritmos genéticos são um ramo dos algoritmos evolucionários baseados em população. Como já mencionado, possuem uma população inicial de amostras que aqui são chamadas de indivíduos. Cada característica do indivíduo é chamado de gene. São estes que representarão aquele indivíduo. Baseado na avaliação da *função de aptidão*, amostras são selecionadas para reprodução.

A etapa de reprodução é dividida em 2 etapas: a primeira é chamada de *Cruzamento* e a segunda é chamada de *Mutação*. Na primeira etapa, baseado em uma probabilidade chamada de probabilidade de *Cruzamento*, dois indivíduos são selecionados aleatoriamente e os seus genes são combinados para assim gerar um novo indivíduo. Existem diversos tipos de operações de cruzamento distintas na literatura, neste trabalho foi utilizada o cruzamento de 1 ponto. Basicamente, escolhe-se de maneira aleatório um ponto em cada um dos 2 indivíduos selecionados e combina-se a primeira parte do primeiro com a segunda parte do segundo e vice-versa, gerando assim dois novos indivíduos, como mostrado na figura 6. Como os indivíduos pais eram bem avaliados, tem-se a chance de gerar um novo


bom indivíduo. Geralmente, usa-se valores altos para esta probabilidade, para ser grande a chance de criar novos indivíduos bons. Existem vários tipos de *Cruzamento* distintos, que variam como os indivíduos serão combinados para criação do novo indivíduo.

Figura 6 – Exemplo de cruzamento em um ponto.



A segunda etapa da reprodução, chamada de *Mutação*, visa aplicar operações aos genes de modo a criar variações de um mesmo indivíduo, baseado em uma probabilidade chamada de probabilidade de *Mutação*. Desse modo, com essa probabilidade, seleciona-se indivíduos aleatoriamente da população e a partir da mesma probabilidade muta-se o gene do indivíduo aleatoriamente, gerando assim um novo indivíduo como visto na figura 7. Neste trabalho, varia-se o índice entre valores de zero a sete.

Figura 7 – Exemplo mutação.



Em seguida, estes novos indivíduos gerados são avaliados com relação à *função de aptidão* e comparados com a população já existente, onde os melhores serão selecionados para ser a nova população na nova iteração do algoritmo. Esta etapa se repete enquanto não atingir um critério de parada, que pode ser uma quantidade de iterações do algoritmo, aqui chamado de gerações ou até encontrar soluções que atinjam algum valor de função objetivo.

2.5.1.1 NSGA-II

O NSGA-II (DEB et al., 2002) é uma técnica de otimi-

zação multiobjetivo baseada em algoritmos genéticos. Esta é uma técnica bastante utilizada por ser de rápida convergência, além de enfatizar soluções não-dominantes, ou seja, soluções que não são melhores que as outras em ambos os objetivos simultaneamente. Além disso, utiliza mecanismos como o *Crowding distance* que é uma técnica de espalhamento de soluções. Este mecanismo avalia a densidade de soluções não-dominadas e assim preserva a diversidade de soluções, perpassando máximos locais. Na figura 8 pode-se ver o algoritmo da técnica NSGA-II que basicamente, ordena a população baseado na avaliação dos objetivos através do *FastNonDominatedSort* (figura 9), utiliza o *Crowding Distance* (figura 10) para

espalhar as soluções e utiliza operadores como seleção, mutação e crossover para geração de novos indivíduos. Para este trabalho, foram utilizadas probabilidades de 10% para mutação e 90% para crossover. Desse modo, tem-se alta probabilidade de gerar novos indivíduos baseado na combinação de bons indivíduos já existentes assim como baixa probabilidade de encontrar máximos locais, ao apenas variar entre características de um único indivíduo ao utilizar a mutação.

Figura 8 – Pseudocódigo NSGA-II.

Algoritmo 1 Pseudocódigo para NSGA-II.

```

1: Inicialize População.
2: Gere N soluções aleatórias e insira em População
3: para i ← 1 até número máximo de gerações faça
4:   Gere PopulaçãoProle de tamanho N.
5:   Selecione os País de População
6:   Crie a Prole de País
7:   Aplique mutação em Prole
8:   Combine População e PopulaçãoProle em PopulaçãoAtual
9:   para todos indivíduos em PopulaçãoAtual faça
10:    Atribua rank baseado no Pareto do FastNonDominatedSort
11:   fim para
12:   Gere conjunto das soluções não-dominadas no Pareto
13:   Calcule o CrowdingDistance
14:   Selecione as N melhores soluções começando no melhor front
15: fim para
16: Retorne os resultados

```

2.5.2 Método de Enxame de Partículas - PSO

A Otimização por Enxame de Partículas é uma técnica de busca heurística que simula o movimento de um bando de pássaros em busca de comida. Esta técnica foi descrita primeiramente por (KENNEDY; EBERHART, 1995), e deste então tem recebido muitas contribuições e aplicações. A maioria das versões multiobjetivo do PSO é baseada nos conceitos de dominância de pareto, como em (COELLO; LECHUGA, 2002), que implementa as etapas do PSO tradicional, acrescentando um operador de turbulência das partículas e um arquivo externo, onde são guardadas as soluções não-dominadas. As etapas deste algoritmo, chamado Multi Objective Particle Swarm Optimization (MOPSO) podem ser vistas no pseudo algoritmo representado na figura 11.

No MOPSO a atualização das velocidades e dos pesos de cada partícula é dada pelas equações 2.1 e 2.2, respectivamente (COELLO; LECHUGA, 2002).

$$v_i(t+1) = \omega(t) \times v_i(t) + c_1(t) \times rand() \times (p_i - x_i(t)) + c_2(t) \times rand() \times (p_g - x_i(t))$$

(2.1)

Figura 9 – Método *FastNonDominatedSort*.**Algoritmo 3** Método *fast-non-dominated-sort*.

```

1: para cada  $p \in P$  faça
2:    $S_p = \emptyset$ 
3:    $n_p = 0$ 
4:   para cada  $q \in P$  faça
5:     se  $(p < q)$  então
6:        $S_p = S_p \cup \{q\}$ 
7:     senão se  $q < p$  então
8:        $n_p = n_p + 1$ 
9:     fim se
10:  fim para
11:  se  $n_p = 0$  então
12:     $p_{rank} = 1$ 
13:     $F_1 = F_1 \cup \{p\}$ 
14:  fim se
15: fim para
16:  $i = 1$ 
17: enquanto  $F_i \neq \emptyset$  faça
18:    $Q = \emptyset$ 
19:   para cada  $p \in F_i$  faça
20:     para cada  $q \in S_p$  faça
21:        $n_q = n_q - 1$ 
22:     se  $n_q = 0$  então
23:        $q_{rank} = i + 1$ 
24:        $Q = Q \cup \{q\}$ 
25:     fim se
26:   fim para
27:   para cada  $q \in Q$  faça
28:      $i = i + 1$ 
29:      $F_i = Q$ 
30:   fim enquanto

```

Figura 10 – Mecanismo *CrowdingDistance*.**Algoritmo 2** Mecanismo de *Crowding Distance*.

```

1:  $N = |F|$ 
2: para  $i \leftarrow 1$  até  $N$  faça
3:    $F[i]_{dist} = 0$ 
4: fim para
5: para  $m \leftarrow 1$  até  $M$  faça
6:   ordene( $F$ ,  $m$ )
7:    $F[1]_{dist} = F[N]_{dist} = \infty$ 
8:   para  $i \leftarrow 2$  até  $N-1$  faça
9:      $F[i]_{dist} = F[i-1]_{dist} + \frac{(F[i+1].m - F[i-1].m)}{f_m^{max} - f_m^{min}}$ 
10:  fim para
11: fim para

```

$$x_i(t+1) = x_i + v_i(t+1) \quad (2.2)$$

Porém na versão discreta do MOPSO, utilizada neste trabalho, existem duas diferenças básicas para o MOPSO para dados contínuos (IZAKIAN; LADANI; ABRAHAM, 2009). A primeira é a representação das velocidades que é feita através de uma matriz de velocidades para cada partícula. Já a segunda diferença está no cálculo das velocidades, que é feito de acordo com o pseudocódigo na figura 12, e das posições, que será o valor no

Figura 11 – Pseudocódigo MOPSO.

Algoritmo 4 Pseudocódigo para MOPSO.

-
- 1: Crie um enxame de partículas e inicialize-as aleatoriamente, respeitando os limites de cada variável.
 - 2: Inicialize o arquivo de soluções A
 - 3: Avalie todas as partículas do enxame
 - 4: Adicione as soluções não-dominadas à A
 - 5: Divida o espaço de busca em hipercubos baseado nos objetivos, onde cada coordenada de cada partícula é definida como sua avaliação para aquele objetivo.
 - 6: Inicialize $P_{best_i}^{\rightarrow} = \vec{X}_i$, para cada partícula i do enxame
 - 7: **enquanto** critério de parada não atingido **faça**
 - 8: Realize sorteio de um hipercubo através de seleção por roleta
 - 9: Realize sorteio aleatório dentre as partículas do hipercubo selecionado
 - 10: Atualize $N_{best_i}^{\rightarrow}$ com a partícula selecionada
 - 11: **fim enquanto**
 - 12: Atualize a velocidade de cada partícula
 - 13: Atualize a posição de cada partícula
 - 14: Aplique o operador de turbulência
 - 15: Avalie todas as partículas do enxame
 - 16: Atualize o coeficiente de inércia ω
 - 17: Atualize A com as partículas não-dominadas
 - 18: **se** arquivo/repositório A cheio **então**
 - 19: Recalcule o espaço de busca dos hipercubos.
 - 20: **fim se**
 - 21: Atualize $P_{best_i}^{\rightarrow}$, caso a posição da partícula seja melhor que a melhor posição armazenada
-

índice da linha da matriz de velocidades que tiver maior velocidade para a dimensão atual, como na equação 2.3.

Figura 12 – Pseudocódigo do Cálculo das velocidades do MOPSO discreto.

Algoritmo 3 Cálculo das velocidades do MOPSO discreto.

-
- 1: **para cada** partícula $k = 1, \dots, P$ **faça**
 - 2: **para cada** dimensão $j = 1, \dots, n$ **faça**
 - 3: $q = X_k(j)$
 - 4: $z = pbest_k(j)$
 - 5: $s = gbest_k(j)$
 - 6: **se** $q \neq z$ **então**
 - 7: $V_k(q, j) = V_k(q, j) - c_1 \times r_1$
 - 8: $V_k(z, j) = V_k(z, j) + c_1 \times r_1$
 - 9: **fim se**
 - 10: **se** $q \neq s$ **então**
 - 11: $V_k(q, j) = V_k(q, j) - c_2 \times r_2$
 - 12: $V_k(s, j) = V_k(s, j) + c_2 \times r_2$
 - 13: **fim se**
 - 14: **fim para**
 - 15: **fim para**
-

$$X_k(j) = \varphi \quad \text{if} \quad V_k(\varphi, j) = \max\{V_k(i, j)\} \quad (2.3)$$

$$\forall j \in (1, 2, \dots, n) \quad \forall i \in (1, 2, \dots, m)$$

O operador de turbulência, aplicado para manter a diversidade das soluções no arquivo que contém as soluções não dominadas é descrito na equação 2.4.

$$P = \left(1 - \frac{iter}{iter_{max}}\right)^{\frac{5}{t-mut}} \quad (2.4)$$


onde, $t-mut$ é um número entre 0 e 1 e P é a probabilidade de ocorrer mutação na partícula atual.

No final da execução obtêm-se, a partir do *Pareto front* presente no arquivo externo, um conjunto de soluções não dominadas que servirão como opções balanceadas de soluções para o problema proposto.

2.5.3 Comparação entre técnicas - Hipervolume e Testes de Hipóteses

Para realizar a comparação entre as técnicas multiobjetivo aplicadas uma medida utilizada na literatura é a métrica de Hipervolume. Ela é calculada a partir das soluções dispostas no Pareto Front obtido. Como pode ser visto na figura 13, um ponto r é escolhido aleatoriamente e o valor do hipervolume é definido como a área compreendida entre o ponto r e as soluções. Valores maiores de hipervolume implicam em um conjunto melhor de soluções. Segundo (RIQUELME; LUCKEN; BARAN, 2015) esta é uma das forma mais utilizadas de analisar este tipo de algoritmo pelo fato de ser capaz de avaliar tanto a acurácia quanto a diversidade do conjunto de soluções em apenas uma métrica. Na operação do sistema é importante que o usuário tenha soluções diversas na recomendação e que sejam balanceadas entre os dois objetivos envolvidos.

Figura 13 – Exemplo de como o hipervolume é calculado.



Além disso, para uma melhor análise dos resultados, diversas simulações utilizando a mesma configuração podem ser realizadas com o intuito de verificar se o comportamento se repete para execuções distintas do mesmo algoritmo utilizando os mesmos parâmetros.

Em seguida, duas amostras aleatórias são selecionadas das execuções e um teste de hipótese é aplicado a elas, com o objetivo de verificar se são estatisticamente semelhantes. Neste trabalho foi utilizado o teste de Wilcoxon que é um teste de hipótese estatístico não-paramétrico. Sendo o resultado do teste positivo, significa que as amostras aleatórias da população são semelhantes e que o comportamento se repetiu para execuções diferentes do algoritmo.

2.6 Conclusão

Nesta seção foram introduzidos conceitos básicos para o bom entendimento deste trabalho. Mostrou-se as principais características e funcionalidades de casas inteligentes e seus sistemas de gerenciamento de energia, além de conceitos de problemas de otimização e técnicas para estes tipos de problema. Por fim duas técnicas distintas foram introduzidas e detalhadas, o NSGA-II, uma técnica baseada em algoritmos genéticos e o MOPSO, baseado em enxame de partículas.

3 Trabalhos Relacionados


Esta seção tem como intuito mostrar trabalhos que possuem problemas similares ao deste ou que propuseram técnicas de solução de problemas que pudessem ser utilizadas para alcançar o objetivo deste trabalho. Inicialmente serão discutidos todos os trabalhos relacionados a este trabalho proposto, que serão resumidos ao fim da seção. por fim o projeto no qual o trabalho desta dissertação está inserido é introduzido e comentado, destacando-se o problema que se deseja otimizar.

São diversas as técnicas presentes na literatura, para gerenciar os aparelhos domésticos de forma automática. Em geral, os trabalhos relacionados a este aprendem o comportamento do usuário e dos aparelhos domésticos e tentam repetí-los, para garantir o conforto do usuário. Por outro lado, a maioria dos trabalhos que utilizam técnicas de otimização para redução de energia buscam parâmetros para aplicar a sistemas, como temperatura para desligar um sistema de refrigeração ou utilizam-se de técnicas para detecção de anomalias ou de *standby* para evitar desperdício de energia. Alguns destes trabalhos serão detalhados a seguir, com ênfase para as etapas dos mesmo que sejam interessantes para o desenvolvimento deste trabalho de dissertação.

([SCHWEIZER et al., 2015](#)) propõe um sistema de redução de energia residencial baseado em comportamento dos usuários da residência. Para tal, uma base dados de uma residência com eventos de ligamento ou desligamento de equipamentos é utilizada como entrada. Cada evento é referenciado por um equipamento e um horário, indicando qual foi a ação tomada para aquele equipamento. Em seguida, um algoritmo de mineração de padrões foi proposto com o intuito de aprender os padrões de eventos dos dados e poder tomar decisões futuras. Baseado nesse algoritmo, um sistema de recomendação foi proposto (vide figura 14. Este sistema é baseado num sistema de regras e eventos, onde um algoritmo de associação é utilizado para combinar as regras e eventos e assim enviar recomendações ao usuário. A medida de conforto utilizada foi baseada na quantidade de recomendações que o sistema faz ao usuário. Como resultado, conseguiu-se uma taxa de 10% de recomendações bem sucedidas, ao se sugerir 0.44 recomendações por dia. Neste trabalho, apesar de visar a redução de energia, valores de cargas não foram levados em consideração.


([CHAO et al., 2010](#)) propôs um sistema de gerenciamento de energia baseado em perfis para equipamentos domésticos. O sistema proposto visa prover dicas de redução de energia para o usuário levando em consideração os perfis de consumo dos equipamentos domésticos, fornecendo dicas que favoreçam o uso eficiente da energia. Como base de dados, foi utilizado o DEHEMS, um ambiente europeu para uso eficiente de energia em

Figura 14 – Sistema de recomendação proposto por (SCHWEIZER et al., 2015) (Figura adaptada).



residências inteligentes. Esse ambiente é baseado em um protocolo *Zigbee* para coletar dados de consumo dos equipamentos e armazenar, como mostrado na figura 15. Dados são capturados por sensores a cada três minutos e os enviam para um servidor central. Além disso, também é mostrada a arquitetura principal do sistema, um sistema baseado em regras e ontologias. Nesse sistema, vários perfis de uso distintos são criados para cada equipamento individualmente. Para uma máquina de lavar, por exemplo, cada programa de lavagem terá um perfil de uso diferente com tempos distintos. Além disso, este sistema leva em consideração as dependências entre os eventos dos equipamentos, como por exemplo um programa de secagem vem após um programa de lavagem numa máquina de lavar. Estas dependências podem ajudar na redução do consumo de energia ao evitar que ações sejam realizadas em ordem incorretas ou repetidamente.


Figura 15 – Arquitetura do sistema utilizado por (CHAO et al., 2010).



(COTTONE et al., 2013) propõe um sistema de reconhecimento de atividades diárias do usuário para redução de energia em casas inteligentes. Para isto, uma análise de dados de sensores é realizada para evitar picos de demanda de energia, causada pelo uso

concorrente de um conjunto de equipamentos que, em conjunto, ultrapassam o consumo máximo permitido pela residência. Além disso, não utilizam nenhum *feedback* do usuário, sendo toda a informação utilizada proveniente dos medidores da rede de sensores. O sistema, como visto na figura 17, converte dados de sensores em eventos utilizando algoritmos de compressão de dados. Em seguida padrões são extraídos dos eventos e agrupados para treinamento de um Modelo Oculto de Markov, o qual implementa um reconhecedor de atividades automatizado. Cada atividade é associada ao seu próprio modelo de consumo de energia, baseado nos equipamentos envolvidos. Ao detectar a atividade que está sendo realizada pelo usuário, o sistema atua a fim de evitar picos de demanda de energia. Por fim, o sistema conseguiu prever possíveis picos de cargas de atividades simuladas e evitá-los.

Figura 16 – Arquitetura do sistema utilizado por (COTTONE et al., 2013).




Em (MAHMOOD et al., 2014) é proposto um esquema de gerenciamento de energia residencial baseado na coordenação dos aparelhos. Uma rede *Zigbee* foi utilizada para permitir a comunicação entre os aparelhos, além de uma unidade central de gerenciamento e medidores inteligentes. O objetivo principal do trabalho é reduzir a conta de energia ao deslocar a operação dos equipamentos de horários de pico para horários fora de pico. Para isso, o sistema recomenda horários convenientes para se começar a usar os equipamentos. O sistema foi utilizado para dados de sete meses e conseguiu reduzir o consumo em horários de pico como esperado.

Já no sistema descrito por (ANVARI-MOGHADDAM et al., 2015), há um gerenciamento térmico de ambientes que utiliza otimização multiobjetivo para encontrar um balanço aceitável entre um estilo de vida confortável e a economia de energia. Através da utilização de funções objetivo sob diferentes restrições e preferências do usuário, o algoritmo proposto conseguiu reduzir a energia além de garantir um escalonamento ótimo de tarefas e uma zona térmica agradável para os ocupantes da residência. Para isto, o sistema gerencia todas as fontes e perdas de energia da residência, considerando diversos fatores diversos. O sistema conseguiu agendar o uso de equipamentos e fontes de geração domésticas de energia levando em consideração o consumo e o conforto do usuário. Seus testes foram realizados através da simulação virtual de uma residência em Sidney, que levava em conta a posição, altitude, janelas, espessura das paredes e o tamanho da residência.

Em (MISSAOUI et al., 2014), foi desenvolvido um modelo capaz de balancear

Figura 17 – Arquitetura do sistema utilizado por (MAHMOOD et al., 2014).



a economia de energia com o conforto do usuário, através do controle de equipamentos residenciais e da integração de energia renovável produzida localmente. O sistema proposto é capaz de otimizar uma integração entre conforto do usuário e custos de energia levando em consideração o *feedback* do usuário e restrições locais como limites de potência e preços de energia. Suas simulações foram feitas utilizando um simulador de fatores relacionados a uma residência ocupada por 4 pessoas em MatLab/Simulink. A figura 18 ilustra um esquema do sistema proposto neste trabalho. O sistema considera informações dos residentes em conjunto com dados da companhia de energia e de tempo de temperatura, além de informações de gerações de energia local e da companhia para controlar os equipamentos locais, como informando a temperatura a ser enviada para os sistemas de refrigeração ou os horários de ligamento e desligamento da máquina de lavar, por exemplo. Ademais, o sistema divide as soluções providas em três modos de operação distintos, baseados nas escolhas do usuário, baseado em redução de energia ou baseado no conforto e assim o sistema calcula em Euros quanto se economizaria em cada modo distinto.

Por fim, (TEICH et al., 2014) desenvolveu um sistema baseado em redes neurais que é capaz de aprender as preferências do usuário e controlar o tempo de aquecimento de uma residência de uma forma eficiente. O sistema funciona de forma que a rede neural aprende o tempo necessário para se chegar a uma determinada temperatura. Com base nisto o elemento ativo só liga com este tempo de antecedência, reduzindo os gastos com ligamento desnecessário do aquecedor. A figura 19 demonstra a estrutura do processo automatizado proposto. Divide-se em um programa responsável por processar os dados, modos de operação e interface com o usuário, um componente neural que provê todo o aprendizado e um elemento ativo que atua sobre os equipamentos.

A importância de sistemas inteligentes SmartHome está no fato deles serem capazes de gerenciar e reduzir o consumo energético dos aparelhos de uma residência de forma automática através de diversas formas de aprendizado dos padrões de uso dos usuários. A

Figura 18 – Arquitetura do sistema utilizado por (MISSAOUI et al., 2014).




Figura 19 – Arquitetura do sistema utilizado por (TEICH et al., 2014).




Tabela 1 – Tabela comparativa dos trabalhos relacionados.

Autor	Dados	Conforto	Perfil de Uso	Redução de Energia	Técnica	Recomendação	Feedback do Usuário
(SCHWEIZER et al., 2015)	Sim	Eventos Liga/Desliga	Não	Sim	Sistema de Regras e Eventos	Sim	Sim
(CHAO et al., 2010)	Sim	Dados de Cargas	Não	Sim	Sistema de Regras e Ontologia	Sim	Sim
(COTTONE et al., 2013)	Sim	Dados de Cargas	Não	Sim	Modelo Oculto de Markov	Sim	Não
(MAHMOOD et al., 2014)	Sim	Dados de Cargas	Sim	Não	Técnica Própria	Sim	Sim
(ANVARI-MOGHADDAM et al., 2015)	Sim	Temperatura e Cargas	Sim	Não	Otimização Multiobjetivo	Sim	Sim
(MISSAOUI et al., 2014)	Sim	Dados de Cargas	Sim	Não	Técnica Própria	Sim	Sim
(TEICH et al., 2014)	Sim	Temperatura	Sim	Não	Redes Neurais	Sim	Sim


tabela 1 faz um resumo comparativo entre os trabalhos relacionados acima descritos.

Dos trabalhos relacionados demonstrados, todos focaram na recomendação de algo ao usuário, desde temperaturas ideais a modos de utilização dos equipamentos. Do mesmo modo, todos utilizaram algum tipo de técnica inteligente para aprendizado ou sugestão de informações. Além disso, alguns trabalhos utilizam dados de consumo de energia de cargas para obter uma medida de conforto. Ainda assim, a maioria deles utilizam algum *feedback* do usuário para atualização dos resultados da técnica. Entretanto, nenhum deles utilizaram dados de consumo de cargas para extração de perfis e medida de conforto aplicados a

técnicas para recomendação.

O trabalho proposto nesta dissertação faz parte de um projeto maior que propõe o desenvolvimento de um sistema de gerenciamento de energia residencial completo, a partir da coleta de dados até a interface final com o usuário, promovendo monitoramento, inteligência, recomendações e controle para o usuário. Este projeto possui, resumidamente, as etapas mostradas na figura 20.

Figura 20 – Etapas do projeto o qual este trabalho faz parte.




A etapa de captação e armazenamento dos dados de consumo de energia dos equipamentos residenciais já foi desenvolvida por um outro trabalho. Neste projeto, denominado Infra-MCR, foi desenvolvido uma arquitetura master-slave capaz de registrar o consumo de energia elétrica individual da carga para uma unidade residencial, além de permitir que o módulo principal do sistema ligue e desligue qualquer carga, através de relés instalados nos circuitos. Os módulos se comunicam e enviam informações via rede elétrica através do protocolo *Power Line Communication (PLC)*. Uma das vantagens dessa tecnologia é o baixo custo, muito importante para incentivar o mercado deste módulo.

A arquitetura do Infra-MCR pode ser vista na figura 21. Os módulos desenvolvidos são compostos de duas placas: Uma placa para a medição do consumo e acoplamento com a rede, chamada Placa de Acoplamento (PA) e outra placa para o microcontrolador e a demodulação e geração do sinal PLC, denominada Placa de Processamento (PP). Os módulos *master* e *slave* são fisicamente idênticos, sendo a única diferença o firmware instalado em cada dispositivo e as interfaces de *Wi-Fi* e com a mídia de armazenamento, presentes apenas no *master*.

Em seguida, deve-se ter um sistema capaz de processar todos os dados de consumo de energia obtidos e tomar decisões em cima deles, fornecendo informações e sugestões de consumo de energia ao usuário, sendo o foco deste trabalho. A etapa final do sistema deve prover toda a interface entre o sistema e o usuário, permitindo que o mesmo acesse todas as informações, receba notificações de atuações automáticas do sistema e tome ações de controle à distância, através de *smartphones* e sistemas de internet. Além disso, esta etapa pode receber *feedback* do usuário para atualização do sistema inteligente do projeto. Como detalhado na figura 20, o foco deste trabalho foi exatamente nas etapas de processamento dos dados e recomendação de utilização ao usuário, visando a redução do consumo de

Figura 21 – Projeto do circuito de monitoramento do consumo de energia.



energia.

Desse modo, o sistema proposto neste trabalho visa aprender o perfil de uso dos equipamentos pelo usuário, e a partir deste aprendizado, recomendar padrões de uso que sejam mais econômicos em termos de energia e parecidos com os atuais.

3.1 Conclusão


Nesta seção foram descritos trabalhos distintos da literatura que têm, de alguma maneira, alguma relação ou relevância com a abordagem proposta neste trabalho. Em seguida, o projeto no qual este trabalho se encaixa foi descrito para ênfase de onde este trabalho deve se encaixar no projeto.

4 RIER - Recomendação Inteligente de utilização de Equipamentos Residenciais

Nesta seção serão apresentados os métodos utilizados para desenvolvimento da proposta desta dissertação. Baseados nos conceitos e estado da arte antes mencionados, aqui serão demonstrados os passos utilizados para obtenção da recomendação inteligente a partir dos dados de consumo de energia e assim alcançar os objetivos. Primeiro, será introduzida a primeira etapa do trabalho na qual a partir da base de dados são encontrados perfis de usos para diferentes equipamentos eletrônicos distintos. Em seguida, será descrita a segunda parte deste fluxo, onde a partir dos perfis de uso de cada equipamento são recomendados opções de perfis de uso visando redução do consumo de energia.

Como já mencionado, um fluxo do projeto do qual este sistema faz parte é demonstrado na figura 22. O projeto se inicia na etapa de captação de dados da casa, geralmente realizado através de uma rede de sensores. Em seguida os dados são tratados, etapa na qual características são extraídas dos dados. Depois, estas características são aplicadas à técnicas de otimização para busca de novos perfis baseados no anterior. Por fim, as recomendações são aplicadas aos equipamentos para utilização. O foco deste trabalho está na recomendação inteligente dos equipamentos domésticos que no projeto é realizada nas etapas de busca de perfis de uso através de extração de características dos dados de consumo e na etapa de recomendação de novos perfis que reduzam o consumo de energia atual sem se afastar do perfil de uso encontrado do equipamento, como enfatizado na figura 22. A seguir serão descritos individualmente os fluxos dessas duas etapas.

Figura 22 – Fluxo de dados completos para recomendação de perfis de uso.




Na primeira etapa, os dados da base de dados utilizada são filtrados e processados para obtenção do perfil de uso para cada equipamento eletrônico individualmente. Em seguida, os perfis de uso são aplicados a técnicas de otimização multiobjetivo para recomendação de perfis de usos distintos que alcancem os objetivo desejados. Ambas etapas e todos os seus passos são detalhados a seguir.

4.1 Identificação dos perfis de uso dos equipamentos

A primeira etapa do sistema se baseia nos padrões de uso dos equipamentos de uma residência, obtidos a partir de dados temporais de potência mensurados por um sistema de automação residencial por um tempo pré-determinado e obtenção de um perfil de uso para cada equipamento. O passo-a-passo para a base de dados selecionada neste trabalho é descrito na figura 23 e detalhado em seguida. Caso outra base de dados fosse selecionada para reaplicação da técnica proposta neste trabalho, as etapas de filtro por equipamento e expansão de amostragem deveriam ser reprojatadas ou até eliminadas.

Figura 23 – Fluxo de operações para obter o perfil de uso do equipamento.




4.1.1 Base de dados

Os dados de consumo dos equipamentos utilizados neste trabalho foram obtidos do repositório UK Domestic Appliance-Level Electricity (UK-DALE) (KELLY, 2015). Esta base de dados foi criada com o intuito de gerar dados de equipamentos desagregados, ou seja, dados individuais de consumo de energia para cada equipamento foram monitorados. A figura 24 mostra o esquema utilizado pelo autor para coleta de dados dos equipamentos. O sistema é composto por 3 componentes principais: Sensores de corrente e tensão, utilizados para captação dessas informações diretamente da tomada do dispositivo, uma placa de som acoplada a um computador que é utilizada como conversor analógico-digital para converter as informações vinda dos sensores e um computador utilizado para armazenar os dados convertidos coletados.

Esta base inclui dados captados de 5 residências e, para cada residência, os dados estão separados por aparelho em séries. Cada série contém, em cada célula, um valor inteiro em formato de *Unix Timestamp*, indicando o segundo exato no qual foi registrado e o valor de potência ativa na forma de um número real.

A casa 1 foi escolhida para testes e validação da técnica proposta neste trabalho. Esta casa possui 54 m² e é residida por 4 ocupantes. Como mostrado na figura 25, 54 equipamentos distintos da casa 1 foram monitorados e a maioria no período de Março de

Figura 24 – Diagrama para coleta de dados dos equipamentos (KELLY, 2015).



2013 a Dezembro de 2014. Além disso, os dados foram monitorados a cada 6 segundos e transmitidos para armazenamento no computador.

Figura 25 – Periodos de monitoramento das residências da base de dados. (KELLY, 2015).




Tabela 2 – Equipamentos selecionados da base dados que possuem maior tempo de monitoramento.

ID	Equipamento	Monitoramento	
		Início	Fim
3	solar_thermal_lamp	11/04/13 19:08:51	03/03/14 13:58:17
6	dishwasher	11/04/13 19:08:51	03/03/14 13:58:17
7	tv	11/04/13 19:08:56	03/03/14 13:58:31
9	htpc	11/04/13 19:08:59	03/03/14 13:58:34
13	microwave	11/04/13 19:08:56	03/03/14 13:58:31
17	amp_livingroom	11/04/13 19:08:54	03/03/14 13:58:34
18	adsl_router	11/04/13 19:08:51	03/03/14 13:58:32
25	lighting_circuit	11/04/13 19:08:48	03/03/14 13:58:34
28	subwoofer_livingroom	11/04/13 19:08:56	03/03/14 13:58:32
32	kitchen_phone&stereo	11/04/13 19:08:58	03/03/14 13:58:33
37	kitchen_radio	11/04/13 19:08:56	03/03/14 13:58:31
38	bedroom_chargers	11/04/13 19:08:57	03/03/14 13:58:32

4.1.2 Separação por equipamento

Como dito na seção 4.1.1, para este trabalho foi escolhida a residência 1, por possuir o maior número de equipamentos monitorados e pelo maior período de tempo. Para esta casa, foram medidos 54 equipamentos distintos. Entretanto, para alguns equipamentos, a leitura não foi constante, por razões diversas como, por exemplo, a troca do equipamento monitorado por um outro equipamento distinto. Além disso, como pode-se ser visto figura 25, alguns equipamentos possuem intervalos de tempo que não foram monitorados. Estes intervalos, se não filtrados, podem provocar inconsistência no processamento do sistema, por sugerir ao sistema que o equipamento estivesse desligado ao longo do intervalo, ao invés de não-monitorado. Desse modo, neste trabalho, estes equipamentos que não foram continuamente monitorados não foram utilizados e, assim, a base de dados que inicialmente era composta por 54 equipamentos foi reduzida para 12 equipamentos.

Os números dos equipamentos, seus nomes e o período monitorado são listados na tabela 2.

4.1.3 Expansão da taxa de amostragem

Para os equipamentos selecionados, o monitoramento foi realizado em intervalos médios de 6 segundos. Logo, pode-se acontecer dos horários de coleta de dias consecutivos não coincidirem, impossibilitando uma comparação do mesmo horário em dias distintos. Um exemplo deste problema pode ser visto na tabela 3.

Desse modo, para permitir a comparação entre dias distintos, foi realizado um aumento de dimensionalidade dos dados, de modo que os intervalos entre os dados fossem reduzidos de 6 segundos para intervalos de 1 segundo. Assim, ao invés de ter-se até 14400

Tabela 3 – Diferença de horário de leitura entre dias consecutivos devido ao intervalo médio de 6 segundos entre as coletas de dados.

25/03/12	P (W)	26/03/12	P (W)
00:00:03	32	00:00:01	31
00:00:09	31	00:00:07	30
00:00:15	31	00:00:03	30

valores para um período de 24 horas, aumentou-se para 86400 valores (24 horas x 60 minutos x 60 segundos), referentes a cada segundo de um período de um dia. Dessa maneira, torna-se possível a comparação e combinação de dias distintos, por ter-se todos os dados de cada dia, referentes a cada segundo.

Para este trabalho, a potência consumida pelo equipamento foi considerada apenas para determinar se o equipamento em questão se encontra desligado ou ligado em um dado instante. Desse modo, sendo a potência consumida maior que 0W o equipamento encontra-se ligado e, por outro lado, caso a potência em um dado instante seja igual a zero, o equipamento é considerado desligado. Dito isto, para preenchimento dos intervalos desconhecidos, foi considerado que caso ambos os valores antecedente e subsequente sejam maiores que zero, então o equipamento foi considerado como ligado naquele intervalo. Caso algum dos valores seja zero, ou seja o equipamento estiver desligado antes ou depois do intervalo, é considerado que o equipamento estava desligado. A tabela 4 demonstra como é feita a expansão de amostragem para os três casos possíveis onde ambos os valores são zero, um deles é zero e ambos são diferentes de zero.

4.1.4 Histograma Semanal

De posse dos dados de consumo para cada segundo de um dia de vários equipamentos, nesta etapa estes dados são agrupados em semanas de uso. Desse modo, obtém-se um histograma semanal de uso para cada equipamento que é gerado pela expressão 4.1. Basicamente um vetor de 86400 posições é criado (todos os segundos de um período de 24 horas) e cada posição é preenchida com a quantidade de vezes que o equipamento esteve ligado naquele instante durante a semana. A criação destes histogramas resultarão numa redução da quantidade de dados para processamento nas próximas etapas desta técnicas mas continuarão representando o histórico de uso do equipamento na semana em questão. Exemplos destes histogramas são mostrado na Figura 26. Pode-se notar que às 18:00:00 o equipamento está ligado em 6 dias, enquanto que um segundo depois, às 18:00:01 está ligado apenas em 5 dias.

Considerando k equipamentos, $1 \leq j \leq 7$ dias da semana e $1 \leq i \leq 86400$ segundos

Tabela 4 – Exemplos de expansão amostral dos dados.

Antes	P(W)	Estado		Depois	P(W)	Estado
				23:17:03	32	Ligado
				23:17:04	-	Ligado
23:17:03	32	Ligado	->	23:17:05	-	Ligado
23:17:09	32	Ligado		23:17:06	-	Ligado
				23:17:07	-	Ligado
				23:17:08	-	Ligado
				23:17:09	32	Ligado

Antes	P(W)	Estado		Depois	P(W)	Estado
				19:24:21	0	Desligado
				19:24:22	-	Desligado
19:24:21	0	Desligado	->	19:24:23	-	Desligado
19:24:27	32	Ligado		19:24:24	-	Desligado
				19:24:25	-	Desligado
				19:24:26	-	Desligado
				19:24:27	32	Ligado

Antes	P(W)	Estado		Depois	P(W)	Estado
				07:08:30	32	Ligado
				07:08:31	0	Desligado
07:08:30	32	Ligado	->	07:08:32	0	Desligado
07:08:36	0	Desligado		07:08:33	0	Desligado
				07:08:34	0	Desligado
				07:08:35	0	Desligado
				07:08:36	0	Desligado

em cada dia, o histograma semanal de uso dos aparelhos é dado por:

$$S_i = \sum_{j=1}^7 l(e_{j,i}) \quad (4.1)$$

onde,

$$l(e_{j,i}) = \begin{cases} 1 & \text{se } x \text{ maior que } 0, \\ 0 & \text{caso contrário.} \end{cases}$$


Resultando em um vetor S contendo 86400 valores inteiros que podem variar de $[0,7]$ de acordo com a quantidade de dias que o equipamento estava em uso naquele segundo específico referente à posição no vetor. A este vetor se dá o nome de Histograma Semanal de uso. Exemplos de histogramas de semanas podem ser vistos na figura 27.

Ademais, este tipo de histograma permite visualizar quais os horários específicos que o equipamento é mais utilizado durante a semana. Neste caso, na primeira parte da figura 27, percebe-se que o equipamento é utilizado 4 vezes por semana no horário em torno dos 25000 segundos, ou seja, em torno das 07:00 da manhã. Além disso, possui de 3

Figura 26 – Processo de criação do histograma semanal de uso.



Figura 27 – Histogramas semanais de uso de equipamentos distintos.



a 4 usos nos horários 62000, 68000 e 78000, ou respectivamente, 17h00, 18h45, 21h. Já o outro equipamento mostrado na segunda parte da figura, seu uso chega a 6 vezes por semana em torno das 19h.

4.1.5 Extração de perfil

Nesta etapa, a partir dos histogramas semanais de cada equipamento, é feita a identificação da semana que possa representar o uso daquele equipamento naquele período de semanas. Para cálculo da similaridade entre as semanas, foi calculada a distância entre todas as semanas, sendo a semana que possui a menor soma de distâncias para as outras a definida como distância centroide do conjunto (HARTIGAN; WONG, 1979). Como medida de distância foi utilizada a distância Euclidiana entre os histogramas semanais, a qual é definida a seguir. Sejam duas semanas s_i e s_j , k o instante em segundos, a distância

Tabela 5 – Matriz D de distâncias entre as n semanas de uso de um equipamento.

	S_1	S_2	...	S_n
S_1	0	$d_{1,2}$		$d_{1,n}$
S_2	$d_{2,1}$	0		$d_{2,n}$
...				
S_n	$d_{n,1}$	$d_{n,2}$		0

Euclidiana entre elas é dada pela equação 4.2.

$$d_{i,j} = \sqrt{\sum_{k=1}^{86400} (s_{i,k} - s_{j,k})^2} \quad (4.2)$$

A partir de todos os cálculos possíveis entre os equipamentos, cria-se uma matriz D que indica a distância entre todas as n semanas do mesmo equipamento, como mostrado na Tabela 5.

Assim, o perfil de uso é dado pelo vetor de características definido pela semana que possui o menor valor para a soma de distâncias d_i para todas as outras n semanas, como mostrado na equação 4.3.

$$d_i = \sum_{j=1}^n d_{i,j} \quad (4.3)$$

Esta semana, por possuir a menor soma de distância para as outras, é chamada de semana centroide e, assim, será utilizada para representar o conjunto de semanas de uso do equipamento em questão.


A depender da modelagem do problema, pode-se agrupar as semanas de um equipamento em conjuntos distintos de acordo com os padrões de uso de cada uma, obtendo assim, mais perfis de uso para o conjunto de dados. Desse modo, pode-se obter grupos distintos com perfis de uso mais detalhados para cada equipamento. Isto pode se tornar interessante quando ocorrem variações de uso do equipamento ao longo do tempo, com relação à época do ano. Assim, podem ser encontrados perfis distintos para estações do ano distintos para um ar condicionado, por exemplo, e assim o sistema de recomendação, que será descrito a seguir, sugerir perfis de uso mais coerentes e que afetem menos o conforto do usuário.

4.2 Sistema de Recomendação Multiobjetivo

A segunda etapa da técnica proposta neste trabalho é a recomendação de um perfil de uso para o usuário. Esta etapa envolve a busca de perfis de uso para o equipamento que diminuam o tempo de uso sem se distanciar muito da forma pela qual o usuário já

utiliza o equipamento. As semanas centroides anteriormente encontradas serão utilizadas como entrada para técnicas de otimização multiobjetivo para obtenção de novos perfis de uso para os equipamentos em direção aos objetivos. Após isto, são sugeridos perfis de uso baseados em diferentes regiões de operação do sistema, que serão detalhadas na seção 5.3. Estas etapas são mostradas na Figura 28 e detalhadas posteriormente.

Figura 28 – Fluxo de etapas para buscar soluções baseadas nos perfis de uso.



4.2.1 Modelagem dos dados

Para se obter um perfil de uso que gaste menos energia e, ao mesmo tempo, seja parecido com o perfil atual do usuário as semanas centroides dos equipamentos foram modeladas e aplicadas a técnicas de otimização multiobjetivo. Nesta etapa, os dados de perfis de uso encontrados para cada equipamento individualmente e o problema de encontrar soluções parecidas com os perfis mas que reduzissem o consumo de energia foram modelados para aplicação em técnicas de otimização multiobjetivo. Neste trabalho foram utilizadas duas técnicas distintas com o intuito de realizar uma análise comparativa entre ambas e ver qual técnica melhor se aplica para busca de soluções deste problema. A modelagem do problema às técnicas foi dividida em três etapas que se iniciam pela identificação de como será uma solução para o problema, quais os objetivos a serem alcançados e quais as restrições para as soluções e para o problema. Este processo é detalhado a seguir.

4.2.1.1 Mapeamento do candidato à solução

Um candidato à solução é, tanto para o NSGA-II como para o MOPSO, um indivíduo (ou partícula no caso do MOPSO) que representará uma semana de uso do equipamento. Como já demonstrado anteriormente, um histograma semanal representa a quantidade de vezes que o equipamento foi utilizado em cada segundo de um dia durante a respectiva semana. Do mesmo modo que a semana centroide é um vetor de 86400 posições onde cada posição varia no intervalo de $[0,7]$, o candidato à solução será no mesmo formato.

Para redução do tempo de simulação e das dimensões dos candidatos à solução, uma análise foi realizada em cima da redução da taxa de amostragem. De forma que a quantidade

de dimensões destes candidatos foi definida como L e, ao invés de se utilizar indivíduos de tamanho 86400 referente a todos os segundos do dia, reduziu-se para intervalos menores. Cada índice da solução será referente a $86400/L$ segundos do perfil de uso recomendado. Quanto maior for o tamanho do L mais o sistema generalizará na solução. Para uma solução de tamanho $L = 2880$, por exemplo, cada índice será referente a 30 segundos e, assim, se a solução sugere um valor 3 para esse índice, significa que durante a semana, naquele intervalo de 30 segundos o equipamento deverá ficar ligado por 3 dias. Portanto, neste trabalho reduziu-se o tamanho de um indivíduo de 86400 segundos para intervalos menores de 30 segundos, 60 segundos, 5 minutos, 10 minutos e 24 minutos, que resultaram em candidatos à solução com tamanhos L iguais a 2880, 1440, 288, 144 e 60, respectivamente. Um exemplo de candidato à solução de tamanho L 144 pode ser visto na figura 29. Cada índice deste candidato equivale a um intervalo de 20 minutos.

Figura 29 – Exemplo de candidato a solução do problema.

1	2	3	4	5	6	7	...	143	144
1	0	2	3	2	3	4	...	5	3

No momento de avaliar os objetivos ou comparar as soluções com o perfil de uso atual, uma solução de tamanho L é expandida para 86400 índices utilizando a expansão amostral mostrada na seção 4.1.3. Assim, seja v o novo vetor de tamanho 86400 criado a partir da solução x . Cada $86400/L$ índices do vetor v será igual ao índice equivalente na solução. Na figura 30 pode ser visto o exemplo de como uma solução de tamanho 144 é expandida para comparação com o perfil de uso do equipamento.

Figura 30 – Exemplo de expansão de um candidato a solução do problema.

1	2	3	4	5	6	7	...	143	144
1	0	2	3	2	3	4	...	5	3

↓

1	2	3	4	5	6	7	...	86400	86400
1	1	1	1	1	1	1	...	3	3

4.2.1.2 Identificação dos Objetivos

Para este trabalho, foram identificados dois objetivos concorrentes entre si. O primeiro é a redução do consumo de energia. Nesse caso, para avaliação da energia da solução proposta foi utilizada a soma total de todos os índices do vetor, obtendo-se o tempo total de uso do equipamento em segundos para a referida semana. Desse modo, ao se reduzir o tempo total de uso do equipamento, reduz-se também a sua energia total consumida.

Sendo assim, a função objetivo 1 que se deseja reduzir é mostrada na equação 4.4. Seja x_i a solução que se deseja avaliar e x_i^{exp} a versão expandida de x_i , com 86400 posições, então:

$$f_1(x_i) = \sum_{k=1}^{86400} x_i^{exp}(k) \quad (4.4)$$

O segundo objetivo identificado neste trabalho foi a proximidade com o perfil atual. Deseja-se buscar soluções que não se afastem do perfil de utilização atual do equipamento pelo usuário. Para avaliação deste objetivo, foi utilizada a distância Euclidiana entre a solução proposta e o perfil de uso do equipamento. De forma que quanto mais próxima a solução do perfil atual, menor será o valor da distância Euclidiana entre ambas. Esta avaliação de objetivo é mostrada na equação 4.5. Seja x_i a solução que se deseja avaliar o segundo objetivo e x_p o perfil de uso, então:

$$f_2(x_i, x_p) = \sqrt{\sum_{k=1}^{86400} (x_i^{exp}(k) - x_p(k))^2} \quad (4.5)$$

Estes objetivos são concorrentes entre si, pois quanto maior a redução do tempo total de uso e conseqüentemente da energia gasta pelo equipamento, maior será a distância Euclidiana entre a solução proposta e o perfil atual de uso.

4.2.1.3 Identificação das restrições

Como restrições na modelagem do problema e dos candidatos, tem-se basicamente duas restrições de valores. A primeira se refere ao tamanho da solução L . Como já dito, neste trabalho para redução da dimensionalidade dos dados e, assim, redução do tempo de simulação dos algoritmos, o tamanho L do indivíduo/partícula foi reduzido. Assim, este tamanho L deve ficar compreendido no intervalo $[1, 86400]$ (número total de segundos de um período de 24 horas). Assim, se o valor de L escolhido for 1, a solução será referente a um período de 24 horas, ou seja, apenas variará na quantidade de dias que o equipamento ficará ligado. Por outro lado, caso o valor máximo de 86400 seja escolhido, o sistema poderá recomendar a quantidade de dias que o equipamento ficará ligado para cada instante em segundos do dia.


Como outra restrição identificada, tem-se que cada índice referente a um intervalo deve conter valores compreendidos no intervalo $[0, 7]$, ou seja, a quantidade de dias durante a semana em que o equipamento deverá ficar ligado no intervalo referente aos $86400/L$ segundos da solução. Caso o valor seja igual a zero, indica que o equipamento deverá ser desligado a semana inteira naquele intervalo. Por outro lado, sendo este valor igual a 7, a solução sugere que o equipamento fique ligado a semana inteira naquele instante.

4.2.2 Otimização multiobjetivo

Nesta etapa após a modelagem dos dados para cada técnica individualmente, as técnicas de otimização multiobjetivo são aplicadas e assim um conjunto de soluções é obtido. Este conjunto de soluções, conhecido como *Pareto Front* é formado pelas melhores soluções encontradas após um certo número de gerações para cada técnica aplicada. Elas são ditas não-dominantes entre si pois nenhuma solução deste conjunto é melhor que outra em ambos os objetivos. Deste modo, cada solução alcança o objetivo desejado, mas a escolha da solução adequada depende do projetista ou, nesse caso, de algum fator ou modo de operação do sistema de recomendação.

A figura 31 exemplifica um conjunto de soluções obtido a partir da aplicação da técnica NSGA-II a um perfil de uso de um equipamento. Cada ponto no gráfico é referente a uma tupla indicada pela avaliação dos dois objetivos que se deseja minimizar, o tempo total de uso do equipamento e a distância para o perfil de uso atual do equipamento. Neste caso pode-se notar que à medida que as soluções se aproximam do eixo x, a distância para o perfil diminui mas o tempo total de uso aumenta. Enquanto que à medida que as soluções se aproximam do eixo y, a distância para o perfil aumenta mas o tempo total de uso diminui, reduzindo o consumo de energia. Vale ressaltar que mesmo as soluções que possuem maior tempo total de uso, este tempo é menor que o perfil de uso do equipamento utilizado, provendo uma redução no consumo de energia, mesmo que mínima.

Figura 31 – Exemplo de conjunto de soluções obtido a partir da otimização multiobjetivo.




4.2.3 Recomendação de uso e modos de operação

A partir do conjunto de possíveis soluções (Pareto Front) retornado pela técnica de otimização, são recomendados perfis de uso para o usuário. Um exemplo de solução obtido por ser visto na figura 32. Na primeira parte da figura pode-se ver o perfil de uso atual do equipamento. Nela é possível notar que o uso semanal do equipamento possui

basicamente dois picos semanais, um em torno de 42000 segundos, ou 11:00 e outro por volta dos 62000 segundos ou 17:00. A solução proposta neste exemplo reduz o tempo total de uso, diminuindo a quantidade de vezes que o equipamento é utilizado. Além disso, mantém a similaridade com o perfil atual de uso, deixando os picos de uso nos mesmos horários.


Figura 32 – Exemplo de solução obtido em comparação com o perfil de uso.



Cada solução do conjunto retornado pelas técnicas de otimização pode ser utilizada de diversas formas distintas. A figura 33 ilustra um exemplo de utilização do conjunto de soluções retornado pelas técnicas de otimização. Este conjunto pode ser dividido em regiões para sugestão distintas dependendo do modo de utilização escolhido. A região 1 poderia ser indicada como um subconjunto de soluções com reduções de consumo mais consideráveis entretanto com distâncias maiores para o perfil de uso atual do equipamento. Já a região 2, pode ser considerada como neutra e demonstra soluções intermediárias entre o consumo e distância para o perfil. Por fim, a região 3 poderia ser considerada como um modo de operação mais leve e que proveriam uma redução menos significativa no consumo de energia.

Outra forma de utilização é a recomendação dos horários de uso do equipamento. Similarmente a um sistema de fichas, o sistema pode acompanhar em tempo real a utilização do equipamento pelo usuário e ir debitando do cota semanal que o usuário possui, informando-o sobre a redução de energia até o dado momento e prevendo quanto será a redução caso continue seguindo o que o sistema sugere.

Figura 33 – Exemplo de conjunto de soluções dividido em regiões para modos de operação distintos.



4.3 Conclusão

Nesta seção foi detalhada a abordagem proposta neste trabalho para redução do consumo de energia em casas inteligentes. Dividida em duas etapas, cada passo de ambas foi detalhado individualmente, a partir dos dados de consumo da base de dados inicial até sugestões de perfis de uso de equipamentos que reduzam o consumo de energia sem se afastar do padrão de uso atual do equipamento.

5 Resultados

Nesta seção serão apresentados e comentados os resultados obtidos com a aplicação da abordagem proposta aos dados da base citada na seção 4.1.1. Primeiramente serão discutidas as etapas para busca dos perfis de uso de cada equipamento. Em seguida, a exploração de parâmetros para cada técnica será comentada, com o detalhamento dos melhores parâmetros encontrados para cada técnica individualmente. Por fim, os resultados obtidos ao se aplicar as técnicas com os melhores parâmetros encontrados aos outros equipamentos são comentados e uma análise entre o desempenho das técnicas é realizado, utilizando-se a métrica de hipervolume.

Para implementação e simulação da técnica proposta foi utilizada a base de dados citada na seção 4.1.1. Dela foram utilizados os 12 equipamentos selecionados (tabela 2). Além disso, as simulações foram realizadas em um ambiente experimental baseado em um Apple Macbook Pro com processador I5 2.5GHz e 4GB de memória RAM. Todos os valores apresentados referentes a tempo de simulação serão baseados neste ambiente.

5.1 Perfis de uso

Na figura 34 pode-se ver um exemplo de semanas de uso do equipamento 25 (*lightning_circuit*). Pode-se notar que apesar das diferenças nos horários e nas quantidades de vezes que o equipamento é utilizado durante os horários, há horários comuns a todas às semanas que o equipamento é utilizado. Por exemplo em torno do horário 25000 em segundos, referente às 7h da manhã. Também tem-se um outro horário comum de uso do equipamento em torno dos 70000 segundos, ou 19h30. A figura 35 mostra o perfil de uso encontrado para o equipamento 25. Este perfil foi encontrado após o cálculo da distância entre todas as 50 semanas de uso do equipamento e, esta semana, possuiu a menor soma das distâncias Euclidianas para as outras.

Figura 34 – Exemplo de semanas distintas de uso do equipamento 25 (*lightning_circuit*).





Figura 35 – Perfil de uso encontrado do equipamento 25 (*lightning_circuit*).

A seguir serão comentados e mostrados os resultados individuais para cada técnica aplicada a apenas um equipamento, em seguida a mesma análise é realizada para três outros equipamentos para analisar se o mesmo compartimento do primeiro equipamento se repete para os outros. Em seguida, as técnicas serão comparadas para ver qual técnica encontra os melhores resultados, baseados nos 12 equipamentos.

5.2 Recomendação de Novos Perfis

Os perfis de uso encontrados na primeira etapa do trabalho foram aplicados a técnicas de otimização para busca de novos perfis. As técnicas NSGA-II e MOPSO foram utilizadas na busca de soluções e para cada uma, foram realizada uma análise paramétrica, para verificar o comportamento das soluções com a variação dos parâmetros. Em paralelo com esta análise foi realizada uma análise comparativa do número de simulações necessárias para execução do algoritmo assim como o tempo total para a execução. Este número de simulações refere-se a quantidade de vezes que a função *fitness* é calculada para cada indivíduo.

5.2.1 NSGA-II

Inicialmente, o NSGA-II foi aplicado à semana centroide do equipamento 25. Com o intuito de se encontrar os melhores parâmetros desta técnica para o problema deste trabalho, simulações foram feitas com exploração dos principais parâmetros. Como parâmetros específicos do NSGA-II, tem-se as probabilidades de *crossover* e mutação. Para estas probabilidades foram utilizados os valores de 90% e 10% respectivamente. A alta probabilidade de *crossover* se dá pelo fato de ser desejável a combinação de indivíduos bons da população atual em busca de novos possíveis bons indivíduos, explorando assim o espaço de busca. Por outro lado, a probabilidade de mutação é baixa para evitar-se muitas

mutações aleatórias nos genes e mínimos locais. A seguir serão comparados e descritos todos os parâmetros utilizados.

5.2.1.1 Análise do número de gerações

A princípio foi feita uma análise de como os resultados se comportam durante a evolução do número de gerações. Para isto, foi escolhido o valor de 200 gerações e a cada 50 gerações uma análise dos conjuntos de soluções foi realizada. A figura 36 mostra como os resultados se comportaram durante as gerações. Pode-se notar que a partir das 100 gerações os resultados pouco variaram entretanto, o número de simulações e o tempo de simulação em muito crescem como visto na figura 37.

Figura 36 – Evolução das soluções com o crescimento das gerações.






Figura 37 – Número de simulações e tempo de simulação com o crescimento do número de gerações.



Já na figura 38 são mostrados os melhores valores encontrados de avaliação das soluções através das gerações. Tanto para a distância para o perfil como para o tempo total de uso, como esperado, os resultados convergiram para o mesmo valor a partir das 100 gerações.

Figura 38 – Convergência dos resultados com o aumento das iterações.



5.2.1.2 Análise do tamanho da população

O valor do tamanho da população foi variado entre os valores de 25, 50, 75 e 100 indivíduos. A figura 39 mostra como as soluções variam após 100 gerações para populações de tamanhos distintos. Como pode-se ver, os resultados foram semelhantes para populações de mais de 50 de indivíduos. Isto pode acontecer devido ao fato de populações maiores permitirem mais opções de combinações nos operadores genéticos e permitirem a saída de máximos locais. Entretanto, como esperado, o número de simulações e o tempo de simulação aumentam consideravelmente com o aumento da população vide figura 40. Desse modo, para este equipamento o melhor valor de população fica em torno de 50 indivíduos.

Figura 39 – Evolução das soluções com o aumento do tamanho da população para 100 gerações.






Figura 40 – Número de simulações e tempo de simulação com o crescimento do tamanho da população.



5.2.1.3 Análise do tamanho do indivíduo L


Um outro parâmetro avaliado neste trabalho foi o tamanho L da solução proposta. Como já mencionado, valores maiores de L indicam soluções mais detalhadas, enquanto que valores menores referem-se a soluções mais generalizadas. A figura 41 ilustra como os conjuntos de soluções se comportaram para diferentes valores de tamanho de indivíduo. Essas simulações foram realizadas utilizando-se 100 gerações e populações de 50 indivíduos. Pode-se notar que para indivíduos menores os resultados foram melhores, mesmo a solução generalizando (ao se sugerir uma mesma quantidade de uso semanal para grandes intervalos de segundos). Entretanto, o tamanho de 60 para L por ser muito pequeno e generalizando demais as soluções encontrou soluções piores que indivíduos de tamanho 144. Nesse caso o número de simulações não varia com a mudança do L , pois o número de indivíduos e número de gerações comparados permaneceram o mesmo. Porém, o tempo de simulação é bastante afetado com o crescimento do L , como visto na figura 41.

Figura 41 – Conjuntos de soluções e tempo de simulação para tamanhos de indivíduos (L) distintos.




5.2.1.4 Verificação dos parâmetros para outros equipamentos

Com o intuito de verificar se análise realizada em cima do tamanho da população, número de gerações e tamanho do indivíduo se repete para outros equipamentos, o mesmo passo-a-passo foi realizado para outros equipamentos como mostrado a seguir. As figuras 42 e 43 demonstram o comportamento dos parâmetros citados para dois outros equipamentos da residência 1 da base de dados. A figura 42 é referente à aplicação do NSGA-II ao perfil de uso do equipamento 28 (*subwoofer_livingroom*). Como pode-se notar, de maneira semelhante ao equipamento 25 anteriormente simulado, a partir de 100 gerações, as soluções convergem para os mesmos resultados, pouco variando para números maiores de gerações. Do mesmo modo, para populações maiores que 50 indivíduos os resultados são pouco afetados. Ademais, o tamanho do indivíduo L se comportou da mesma maneira, mostrando que indivíduos menores encontram soluções mais próximas ao *Pareto front* do conjunto de soluções.

Figura 42 – Soluções para o equipamento 28 (*subwoofer_livingroom*).

De modo semelhante, acontece com o equipamento 38 (*bedroom_chargers*). A partir de 50 gerações os resultados pouco variam, sendo melhores avaliados os menores indivíduos e populações de tamanho 50.

Figura 43 – Soluções para o equipamento 38 (*bedroom_chargers*).

5.2.2 MOPSO

De modo semelhante ao NSGA-II, os perfis de uso anteriormente encontrados para os equipamentos da residência 1 da base de dados foram aplicados à técnica MOPSO. Alguns parâmetros específicos do MOPSO foram definidos através de estudos empíricos da literatura, como o peso de inércia, coeficientes de aceleração $c1$ e $c2$ e probabilidade de mutação. Como descrito por (BERGH, 2001), valores para o peso de inércia entre $[0.8, 1.2]$ implicam em rápida convergência, porém quanto maior mais essa convergência pode ser comprometida. Sendo assim, foi utilizado o valor de 0.8 para este peso. Do mesmo modo, este autor indica que são mais desejáveis valores para os coeficientes $c1$ e $c2$ iguais a 2, como definido pelo PSO original. Além disso, a probabilidade de mutação utilizada foi 0.4.

A seguir será descrito como os conjuntos de soluções se comportaram ao se variar os parâmetros de número de partículas, número de iterações e o tamanho de partícula L . Para estas simulações foi utilizado o perfil de uso do equipamento 25 (*lightning_circuit*) e em seguida os parâmetros foram validados para outros equipamentos.

5.2.2.1 Avaliação do número de iterações

Para o problema deste trabalho, o MOPSO foi capaz de encontrar boas soluções já a partir de poucas iterações de simulação, como é possível ver na figura 44. Nela é

possível notar que já a partir de 50 iterações as soluções pouco melhoraram em direção ao *Pareto front*. Além disso, na figura 45 pode-se ver que tanto o número de simulações como o tempo de simulação crescem de maneira constante com o aumento do número de iterações. Merece atenção o crescimento do tempo de simulação. Com o aumento do número de iterações, o tempo para uma simulação chega a aumentar de 100 segundos para até 800 segundos, 4 vezes mais.

Figura 44 – Comportamento das soluções com o aumento das iterações.





Figura 45 – Evolução do número de simulações e tempo de simulação com o aumento das iterações.



5.2.2.2 Avaliação do número de partículas

Quanto ao número de partículas, foi possível notar que mesmo para valores pequenos para o total de partículas, como 25, por exemplo, já conseguiram alcançar bons resultados, após 50 iterações, como visto na figura 46. Com o aumento do número de partículas, explora-se melhor o espaço de busca ao se iniciar aleatoriamente mais partículas. Outrossim, através da figura 47 vê-se que o número de simulações e tempo de simulação é totalmente proporcional ao número de partículas, crescendo bastante para grandes quantidades de partículas. Desse modo, percebe-se que para o problema deste trabalho, pode-se utilizar pequenos tamanhos de enxames para economizar em tempo de simulação.

Figura 46 – Comportamento das soluções para cada número de partículas.





Figura 47 – Evolução do número de simulações e tempo de simulação com o aumento do número de partículas.



5.2.2.3 Avaliação do tamanho da partícula L

A seguir pode ser visto a variação do conjunto de soluções para partículas de tamanhos distintos. Neste caso, foram utilizadas partículas de tamanho 2880, 1440, 288, 144, referentes a intervalos de 30 segundos, 60 segundos, 5 minutos e 10 minutos, respectivamente. Para os valores menores as soluções foram melhores, como visto na figura 48. Isto indica que indivíduos menores foram mais explorados e isto implicou num tempo de simulação muito menor, como mostrado na figura 49.

5.2.2.4 Verificação dos parâmetros para outros equipamentos

De modo semelhante ao NSGA-II, o MOPSO foi aplicado a dois outros equipamentos para verificar se o comportamento das soluções se repete. Assim, a mesma análise realizada para o equipamento 25 (*lightning_circuit*) foi aplicada aos equipamentos 28 (*subwoofer_livingroom*) e 38 (*bedroom_chargers*).

Primeiramente, na figura 50 são mostrados os resultados das simulações do MOPSO para o equipamento 28 (*subwoofer_livingroom*). Com resultados similares, pode-se notar

Figura 48 – Comportamento das soluções para partículas de tamanhos distintos.






Figura 49 – Evolução do tempo de simulação para diferentes tamanhos de partículas.



que as soluções são parecidas mesmo a partir das 25 iterações para uma simulação da técnica. Já para o número de partículas, para este equipamento praticamente não houve diferença para o tamanho do enxame. Tanto para pequenos enxames de 25 partículas como para maiores de 100 partículas os resultados foram parecidos. Entretanto, para o tamanho L da partícula, o resultado foi similares a outros já encontrados. Partículas menores de tamanho 144 encontraram melhores resultados, enquanto que para partículas maiores os resultados foram mais distantes do *Pareto front*.


Figura 50 – Soluções do MOPSO para o equipamento 28 (*subwoofer_livingroom*).

A figura 51 ilustra os resultados obtidos para a simulação do MOPSO para o

Tabela 6 – Melhores parâmetros encontrados para o NSGA-II.

Nome	Valor
Quantidade de Indivíduos	50
Número de Gerações	100
Dimensão dos Indivíduos	144
Probabilidade de Cruzamento	90%
Probabilidade de Mutação	10%

equipamento 38 (*bedroom_chargers*). Com resultados equivalentes, percebe-se que mesmo a partir de 25 iterações os resultados pouco variaram. Assim também aconteceu para o número de partículas na simulação. Resultados melhores apareceram para enxames maiores, mas, mesmo assim, para números de partículas maiores que 50 os resultados já foram aproximados. Por fim, como análise do tamanho L da partícula, para este equipamento o mesmo resultado se repetiu. Partículas de tamanho 144 obtiveram os melhores resultados, de modo análogo aos outros equipamentos.

Figura 51 – Soluções do MOPSO para o equipamento 38 (*bedroom_chargers*).

5.2.3 Comparações entre as técnicas

Para comparar o desempenho das técnicas, o NSGA-II e o MOPSO foram aplicados aos dados de outros equipamentos, utilizando os melhores parâmetros encontrados para os equipamentos acima analisados, mostrados na tabela 6 para o NSGA-II e tabela 7 para o MOPSO. Para cada equipamento testado e para cada técnica, foram executadas 30 simulações e, de maneira aleatória, duas amostras foram selecionadas e aplicadas ao teste de hipótese de Wilcoxon (como citado na seção 2.5.3).


Desse modo, as técnicas foram aplicadas aos dados de cinco equipamentos selecionados da tabela 2 (3 - solar_thermal_lamp, 6 - dishwasher, 7 - tv, 9 - htpc, 13 - microwave) e, para cada equipamento, foram realizadas 30 simulações. Em seguida, para cada equipamento, duas amostras foram selecionadas aleatoriamente e aplicadas ao teste de hipótese de Wilcoxon, para verificar se o comportamento dos resultados eram estatisticamente semelhantes. Em todos os casos (e para ambos os algoritmos) os resultados foram positivos, significando que as soluções encontradas tinham comportamento semelhante nas simulações selecionadas.

Tabela 7 – Melhores parâmetros encontrados para o MOPSO.

Nome	Valor
Quantidade de Partículas	50
Número de Iterações	50
Dimensão das partículas	144
$c1$ e $c2$	2
Peso de inércia	0.8
Probabilidade de Mutação	40%
Fatores de divisão da grade adaptativa	5,5

Desse modo, escolheu-se aleatoriamente para outros os equipamentos outra solução de cada simulação e o valor do hipervolume foi calculado. Os resultados em valor de hipervolume e tempo de simulação para as duas técnicas são mostrados na figura 52.

Figura 52 – Valores de hipervolume e de tempo de simulação para as duas técnicas nos equipamentos analisados.



Com base nos valores de hipervolume, pode-se ver que o NSGA-II, possivelmente, pelo fato de ter uma capacidade maior de exploração do espaço de busca, conseguiu encontrar melhores soluções para todos os equipamentos testados. Além disso, possui tempo de simulação bem mais baixo que o MOPSO para simulações dos melhores parâmetros. Desse modo, nota-se que o NSGA-II é a técnica mais indicada para este sistema proposto.

5.3 RIER - Resultados para redução de Energia

A abordagem proposta neste trabalho pode ser implementada e aplicada a diversos equipamentos de uma residência, permitindo assim, uma redução no consumo de energia dos equipamentos em conjunto. Como visto na seção 5.2.3, a técnica NSGA-II foi a que obteve os melhores resultados para a simulação deste problema. Sendo assim um cenário criado é com um exemplo de redução de energia se caso a abordagem proposta fosse aplicada aos 12 equipamentos descritos na tabela 2.


Neste cenário, os conjuntos de soluções encontrados através da técnica NSGA-II, foram divididos em 3 regiões. Como já explicado na seção 4.2.3, a região 1 é referente a soluções que possuem um maior distância para o perfil por produzirem uma redução de energia mais considerável. Por outro lado, a região 3 seria uma região que menos afetaria o conforto do usuário, por possuir menor distância para o perfil atual de uso do equipamento. Entretanto, soluções desta região produzem uma menor redução do consumo de energia. Por fim, a região 2 é referente a soluções intermediárias entre as regiões 1 e 3.

Desta maneira, todos equipamentos selecionados foram simulados com a técnica NSGA-II e os resultados foram divididos em três regiões distintas de tamanhos similares. Para facilitar a comparação, uma solução central foi escolhida de cada região e comparada com as demais. Este procedimento será descrito e em seguida um exemplo com todos os equipamentos será mostrado.

5.3.1 Exemplo de Redução de Energia para um Equipamento

Na primeira parte da figura 53 pode-se ver um exemplo de perfil encontrado para o equipamento 3 (*solar_thermal_lamp*). Além disso, na segunda parte desta mesma figura, tem-se o percentual de redução alcançado para soluções obtidas da aplicação da técnica de otimização utilizando os parâmetros mostrados na tabela 6. Acompanhando a ideia anterior do *Pareto front*, à medida que o conforto diminui, o percentual de redução de energia também diminui. Percebe-se que as soluções variam entre 40% e 70% de redução de energia para o perfil atual.

Figura 53 – Perfil de Uso encontrado e Soluções obtidas pelo NSGA-II para o equipamento 3 (*solar_thermal_lamp*) e seus percentuais de redução.



Então, este conjunto de soluções foi ordenado pelo percentual de redução de consumo e dividido em três regiões de mesmo tamanho, nesse caso 17 soluções para cada região, como pode ser visto na figura 54.

Em seguida, para cada região do conjunto de soluções obtido, uma solução central foi escolhida. Os histogramas expandidos de uso destas três soluções podem ser vistos

Figura 54 – Soluções divididas em regiões e soluções selecionadas de cada região do equipamento 3 (solar_thermal_lamp).




Tabela 8 – Redução de energia para soluções selecionadas do eq. (solar_thermal_lamp).

Solução	Região	Distância para o perfil	Tempo total de Uso	Redução
1		430	40200	66%
2		373	52800	55%
3		319	65400	44%

na figura 55. Além disso, na tabela 8, pode-se ver os valores de redução de energia para cada solução selecionada. Em comparação com o perfil da figura 53, a primeira solução possui um histograma mais econômico, sendo a solução sugerida de tempo valor total de uso (e conseqüentemente menor energia), a segunda já possui uma utilização (e uma menor redução de energia) e a terceira maior ainda. Sabendo-se que o perfil de uso deste equipamento mostrado possui um tempo total de uso de 117937 segundos, encontrou-se que as soluções encontradas obtiveram, respectivamente, 66%, 55% e 44% de redução do tempo de uso e, por conseguinte, do consumo de energia.

Além do mais, para estas execuções do algoritmo, o número de simulações ficou em torno de 4000 simulações, ou seja, 4000 indivíduos do espaço de busca foram avaliados. Sendo o espaço de busca da ordem de 8^{86400} (86400 índices de 8 posições cada - [0 7]), explorou-se um subconjunto mínimo deste espaço, em apenas 15 segundos, encontrando-se boas soluções para o problema.

Figura 55 – Exemplos de soluções encontradas para o eq. (solar_thermal_lamp).




Tabela 9 – Reduções mínimas e máximas para cada equipamento referentes às melhores soluções encontradas.

ID	Descrição	Redução Mínima	Redução Máximas
3	solar_thermal_lamp	42%	65%
6	dishwasher	42%	66%
7	tv	43%	64%
9	htpc	38%	61%
13	microwave	41%	64%
17	amp_livingroom	29%	76%
18	adsl_router	46%	65%
25	lighting_circuit	81%	47%
28	subwoofer_livingroom	41%	62%
32	kitchen_phone&stereo	43%	63%
37	kitchen_radio	39%	61%
38	bedroom_chargers	41%	76%

5.3.2 Redução de Energia para vários Equipamentos

Nesta etapa, seguindo a mesma ideia da seção 5.3, a técnica NSGA-II foi aplicada a todos os 12 equipamentos selecionados. Na tabela 9 pode-se ver as reduções mínimas e máximas encontradas para cada equipamento distinto. Alguns equipamentos encontraram soluções melhores que outros por serem de menor uso semanal ou por possuírem um uso mais contínuo. Em seguida, a partir da divisão das soluções em regiões e seleção de uma solução central por região, tem-se uma média de redução para os 12 equipamentos em conjunto.


Na figura 56 pode-se ver uma média de redução de energia para os 12 equipamentos simulados em conjunto. Apesar de não serem todos os equipamentos da residência simulada, dá para se notar que o compartimento da abordagem proposta se repetiu para os equipamentos e foi possível obter médias de redução de consumo de energia de 45% a até 65%. Variando entre soluções com reduções mais consideráveis a soluções com reduções de energia menos impactantes, afetando menos o conforto do usuário.

Na prática estes resultados poderiam ser apresentados a algum usuário e, baseado no modo de operação escolhido, um acompanhamento da utilização dos equipamentos poderia ser realizado para assim sugerir desligar os equipamentos quando fossem utilizados fora do horário recomendado. Utilizando-se dados reais de consumo dos equipamentos, ao invés da base de dados, perfis reais podem ser obtidos e aplicados ao sistema inteligente.

5.4 Conclusão

Nesta seção foram apresentados os resultados obtidos para simulação da técnica proposta no ambiente experimental descrito. Inicialmente foram mostrados e descritos

Figura 56 – Percentual de redução médio ao se aplicar a abordagem a todos os equipamentos por região de conforto.



exemplos de perfis de uso encontrados para um equipamento selecionado da casa. Em seguida, parâmetros das técnicas de otimização NSGA-II e MOPSO foram simulados e avaliados, em busca dos melhores parâmetros para o problema deste trabalho. Por fim, todos os equipamentos selecionados foram simulados e as soluções divididas em regiões, provendo reduções de consumo de energia de 40% a até 70%, a depender da região. Como já dito anteriormente, até o presente momento não há métodos parecidos na literatura que a partir da mesma fonte de dados produza o mesmo tipo de saída para assim permitir a comparação dos resultados. Trabalhos na literatura buscam encontrar perfis de uso dos equipamentos para outro tratamento com as informações, ou buscam controlar os equipamentos diretamente para reduzir o consumo de energia. Neste trabalho, encontrou-se perfis de uso dos equipamentos para recomendação de novos perfis, visando a redução, sem afetar o consumo.

6 Conclusão

Nesta seção serão apresentados os comentários finais deste trabalho de dissertação, começando pelos resultados obtidos para perfis de equipamentos, seguidos por resultados encontrados por cada técnica e resumo da redução de energia obtida. Por fim, serão comentados alguns trabalhos futuros que poderão ser realizados como continuação deste trabalho.

Através deste trabalho foi proposta uma abordagem de recomendação de uso de equipamentos para redução de energia em casas inteligentes. Para isso, foi proposta uma técnica baseada em perfis de uso atuais de cada equipamento e utilizou-se técnicas de otimização multiobjetivo para encontrar perfis de uso que sejam de menor consumo energético, mas que sejam similares aos perfis de uso atuais do usuário. Estes perfis de saída podem ser aproveitados de muitas maneiras como, por exemplo, para recomendar os horários de uso de cada equipamento ou recomendar cotas de uso semanal através de uma meta de gastos com energia.

A abordagem proposta possui duas etapas principais. A primeira tem como objetivo obtenção dos perfis de utilização dos equipamentos a partir de dados de consumo de energia coletados periodicamente. A segunda etapa busca novos perfis de utilização de equipamentos através de utilização de técnicas multiobjetivo a partir do perfil de utilização atual.

Para encontrar os perfis de uso dos equipamentos a partir da base de dados, uma técnica utilizando centroides e distância Euclidiana foi utilizada, para encontrar a semana que possuisse a menor soma de distâncias para as outras, indicando que esta poderia representá-las.

Em seguida, estes perfis de uso de cada equipamento foram aplicados às técnicas de otimização NSGA-II e MOPSO em busca de novos perfis de uso que fossem similares aos perfis encontrados mas que possuissem um tempo total de uso menor que o atual, reduzindo assim a energia consumida. Para cada técnica foi realizada uma busca pelos melhores parâmetros que compensassem em número de simulações e tempo de simulação. Em seguida, as técnicas foram aplicadas a outros equipamentos e comparadas utilizando a métrica de hipervolume. Nos resultados obtidos, a técnica NSGA-II obteve os melhores resultados para todos os equipamentos testados.

Em seguida, para um conjunto de soluções obtido, foi proposto um exemplo de como as soluções podem ser utilizadas, ao se dividí-las em regiões. Cada região seria formada por soluções que ou se afastam mais do perfil atual mas que reduzem mais energia ou que sejam mais próximas do perfil mas que provoquem uma redução menor no consumo de energia. Para a região com reduções menos consideráveis, obteve-se uma média de 45%

Tabela 10 – Tabela comparativa dos trabalhos relacionados.

Autor	Dados	Conforto	Perfil de Uso	Redução de Energia	Técnica	Recomendação	Feedback do Usuário
(SCHWEIZER et al., 2015)	Sim	Eventos Liga/Desliga	Não	Sim	Sistema de Regras e Eventos	Sim	Sim
(CHAO et al., 2010)	Sim	Dados de Cargas	Não	Sim	Sistema de Regras e Ontologia	Sim	Sim
(COTTONE et al., 2013)	Sim	Dados de Cargas	Não	Sim	Modelo Oculto de Markov	Sim	Não
(MAHMOOD et al., 2014)	Sim	Dados de Cargas	Sim	Não	Técnica Própria	Sim	Sim
(ANVARI-MOGHADDAM et al., 2015)	Sim	Temperatura e Cargas	Sim	Não	Otimização Multiobjetivo	Sim	Sim
(MISSAOUI et al., 2014)	Sim	Dados de Cargas	Sim	Não	Técnica Própria	Sim	Sim
(TEICH et al., 2014)	Sim	Temperatura	Sim	Não	Redes Neurais	Sim	Sim
RIER	Sim	Dados de Cargas	Sim	Sim	Otimização Mmultiobjetivo	Sim	Não

de redução de energia. Já para a região com soluções mais consideráveis, obteve-se uma média de redução de 65%.

Como mostrado, o conjunto obtido provê a liberdade de escolha para o sistema de recomendação a depender do modo de operação, o qual influencia na flexibilidade para mudança no perfil atual de uso do equipamento e na redução de consumo desejada pelo usuário.

A tabela 10 mostra a tabela comparativa entre os trabalhos relacionados anteriormente descritos e este trabalho. Apesar deste trabalho por enquanto não utilizar nenhum *feedback* do usuário, permitiu utilizar dados de cargas para obtenção de perfis de uso dos equipamentos e recomendar modos de utilização para redução de energia baseado no conforto do usuário.

6.1 Trabalhos Futuros

Como continuação desta pesquisa, pretende-se utilizar técnicas de aprendizado de máquina para se detectar a semana centroide com mais eficácia. Além disso, o trabalho pode ser expandido para um maior detalhamento das divisões dos dados para determinação dos perfis de uso, obtendo, assim, perfis mais detalhados para épocas distintas de uso.

Ademais, a aplicação de outras técnicas de otimização multiobjetivo na recomendação, a fim de encontrar uma que seja robusta com relação aos diversos padrões de utilização dos equipamentos.

Referências

- Agência Nacional de Energia Elétrica. *Micro e Mini geração Distribuída*. [S.l.], 2014. Citado 2 vezes nas páginas 14 e 15.
- Agência Nacional de Energia Elétrica. *Bônus incentiva troca de eletrodomésticos antigos por novos*. [S.l.], 2015. Citado na página 14.
- ANVARI-MOGHADDAM, A. et al. Optimal smart home energy management considering energy saving and a comfortable lifestyle. *IEEE Trans. Smart Grid*, Institute of Electrical & Electronics Engineers (IEEE), v. 6, n. 1, p. 324–332, jan 2015. Disponível em: <http://dx.doi.org/10.1109/TSG.2014.2349352>. Citado 3 vezes nas páginas 33, 35 e 68.
- BERGH, F. van den. *An analysis of particle swarm optimizers*. Tese (Doutorado) — University of Pretoria, Pretoria, 11 2001. Citado na página 57.
- CHAO, K.-M. et al. A profile based energy management system for domestic electrical appliances. In: *2010 IEEE 7th International Conference on E-Business Engineering*. Institute of Electrical & Electronics Engineers (IEEE), 2010. Disponível em: <http://dx.doi.org/10.1109/ICEBE.2010.23>. Citado 5 vezes nas páginas 10, 31, 32, 35 e 68.
- COELLO, C. C.; LECHUGA, M. MOPSO: a proposal for multiple objective particle swarm optimization. In: *Proceedings of the 2002 Congress on Evolutionary Computation. CEC02 (Cat. No.02TH8600)*. Institute of Electrical & Electronics Engineers (IEEE), 2002. Disponível em: <http://dx.doi.org/10.1109/CEC.2002.1004388>. Citado na página 26.
- COTTONE, P. et al. User activity recognition for energy saving in smart homes. In: *2013 Sustainable Internet and ICT for Sustainability (SustainIT)*. Institute of Electrical & Electronics Engineers (IEEE), 2013. Disponível em: <http://dx.doi.org/10.1109/SustainIT.2013.6685196>. Citado 5 vezes nas páginas 10, 32, 33, 35 e 68.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, Institute of Electrical & Electronics Engineers (IEEE), v. 6, n. 2, p. 182–197, apr 2002. Disponível em: <http://dx.doi.org/10.1109/4235.996017>. Citado na página 25.
- Empresa de Pesquisa Energética (EPE). *Estudos da eficiência energética - Consumo de energia no Brasil*. 2014. URL: <http://www.epe.gov.br/mercado/Documents/Serie%20Estudos%20de%20Energia/DEA%2010-14%20Consumo%20de%20Energia%20no%20Brasil.pdf>. Citado na página 14.
- GANZ, F. et al. A practical evaluation of information processing and abstraction techniques for the internet of things. In: *IEEE Internet of Things Journal (Volume:2 , Issue: 4)*. [S.l.]: IEEE, 2015. p. 340–354. Citado 2 vezes nas páginas 15 e 16.
- GROSAN, C.; ABRAHAM, A. Hybrid evolutionary algorithms: Methodologies, architectures, and reviews. In: *Hybrid Evolutionary Algorithms*. Springer Science + Business

Media, 2007. p. 1–17. Disponível em: <http://dx.doi.org/10.1007/978-3-540-73297-6_1>. Citado na página 24.

HALL, D.; LLINAS, J. An introduction to multisensor data fusion. *Proceedings of the IEEE*, Institute of Electrical & Electronics Engineers (IEEE), v. 85, n. 1, p. 6–23, 1997. Disponível em: <<http://dx.doi.org/10.1109/5.554205>>. Citado na página 22.

HAN, J.; CHOI, C.-S.; LEE, I. More efficient home energy management system based on ZigBee communication and infrared remote controls. In: *2011 IEEE International Conference on Consumer Electronics (ICCE)*. Institute of Electrical & Electronics Engineers (IEEE), 2011. Disponível em: <<http://dx.doi.org/10.1109/ICCE.2011.5722779>>. Citado na página 20.

HARTIGAN, J. A.; WONG, M. A. Algorithm AS 136: A k-means clustering algorithm. *Applied Statistics*, JSTOR, v. 28, n. 1, p. 100, 1979. Disponível em: <<http://dx.doi.org/10.2307/2346830>>. Citado 2 vezes nas páginas 22 e 44.

HODGE, V.; AUSTIN, J. A survey of outlier detection methodologies. *Artificial Intelligence Review*, Springer Science + Business Media, v. 22, n. 2, p. 85–126, oct 2004. Disponível em: <<http://dx.doi.org/10.1023/B:AIRE.0000045502.10941.a9>>. Citado na página 22.

IZAKIAN, H.; LADANI, B. T.; ABRAHAM, A. *A DISCRETE PARTICLE SWARM OPTIMIZATION APPROACH FOR GRID JOB SCHEDULING*. 2009. Citado na página 27.

KELLY, J. *UK Domestic Appliance Level Electricity (UK-DALE) - Disaggregated (6s) appliance power and aggregated (1s) whole house power*. [S.l.], 2015. Disponível em: <<http://dx.doi.org/10.5286/UKERC.EDC.000001>>. Citado 3 vezes nas páginas 10, 39 e 40.

KELLY, J.; KNOTTENBELT, W. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. *Scientific Data*, v. 2, n. 150007, 2015. Citado na página 21.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: *Proceedings of ICNN95 - International Conference on Neural Networks*. Institute of Electrical & Electronics Engineers (IEEE), 1995. Disponível em: <<http://dx.doi.org/10.1109/ICNN.1995.488968>>. Citado na página 26.

KIM, S. et al. Restful design and implementation of smart appliances for smart home. In: *2014 IEEE 11th Intl Conf on Ubiquitous Intelligence and Computing and 2014 IEEE 11th Intl Conf on Autonomic and Trusted Computing and 2014 IEEE 14th Intl Conf on Scalable Computing and Communications and Its Associated Workshops*. Institute of Electrical & Electronics Engineers (IEEE), 2014. Disponível em: <<http://dx.doi.org/10.1109/UIC-ATC-ScalCom.2014.64>>. Citado na página 19.

LI, B. et al. Predicting user comfort level using machine learning for smart grid environments. In: *Innovative Smart Grid Technologies (ISGT), 2011 IEEE PES*. [S.l.]: IEEE, 2011. p. 1–6. ISBN 978-1-61284-219-6. Citado na página 15.

MAHMOOD, A. et al. Home appliances coordination scheme for energy management (HACS4em) using wireless sensor networks in smart grids. *Procedia Computer Science*, Elsevier BV, v. 32, p. 469–476, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.procs.2014.05.449>>. Citado 5 vezes nas páginas 10, 33, 34, 35 e 68.

MISSAOUI, R. et al. Managing energy smart homes according to energy prices: Analysis of a building energy management system. *Energy and Buildings*, Elsevier BV, v. 71, p. 155–167, mar 2014. Disponível em: <<http://dx.doi.org/10.1016/j.enbuild.2013.12.018>>. Citado 4 vezes nas páginas 10, 33, 35 e 68.

MULTI-OBJECTIVE Management in Freight Logistics. Springer Nature, 2008. Disponível em: <<http://dx.doi.org/10.1007/978-1-84800-382-8>>. Citado na página 23.

RIQUELME, N.; LUCKEN, C. V.; BARAN, B. Performance metrics in multi-objective optimization. In: *2015 Latin American Computing Conference (CLEI)*. Institute of Electrical & Electronics Engineers (IEEE), 2015. Disponível em: <<http://dx.doi.org/10.1109/CLEI.2015.7360024>>. Citado na página 29.

SCHWEIZER, D. et al. Using consumer behavior data to reduce energy consumption in smart homes: Applying machine learning to save energy without lowering comfort of inhabitants. In: *2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA)*. Institute of Electrical & Electronics Engineers (IEEE), 2015. Disponível em: <<http://dx.doi.org/10.1109/ICMLA.2015.62>>. Citado 5 vezes nas páginas 10, 31, 32, 35 e 68.

SERRANO, J. I.; CASTILLO, M. D. del. On the origin of the evolutionary computation species influences of darwin's theories on computer science. *Artificial Intelligence Review*, Springer Science + Business Media, v. 38, n. 1, p. 41–54, may 2011. Disponível em: <<http://dx.doi.org/10.1007/s10462-011-9246-6>>. Citado na página 23.

SHAIKH, P. H. et al. A review on optimized control systems for building energy and comfort management of smart sustainable buildings. *Renewable and Sustainable Energy Reviews*, Elsevier BV, v. 34, p. 409–429, jun 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rser.2014.03.027>>. Citado na página 15.

TEICH, T. et al. Design of a prototype neural network for smart homes and energy efficiency. *Procedia Engineering*, Elsevier BV, v. 69, p. 603–608, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.proeng.2014.03.032>>. Citado 4 vezes nas páginas 10, 34, 35 e 68.

U.S. Energy Information Administration. *International Energy Outlook 2016*. [S.l.], 2016. Citado na página 14.

VAZQUEZ, F. I.; KASTNER, W.; REINISCH, C. Impact of user habits in smart home control. In: *ETFA2011*. Institute of Electrical & Electronics Engineers (IEEE), 2011. Disponível em: <<http://dx.doi.org/10.1109/ETFA.2011.6059104>>. Citado na página 14.

World Trade Organization. *World Trade Report 2010*. [S.l.], 2010. Citado na página 14.

YANG, S.-H. et al. A case study of internet of things: A wireless household water consumption monitoring system. In: *2015 IEEE 2nd World Forum on Internet of Things (WF-IoT)*. Institute of Electrical & Electronics Engineers (IEEE), 2015. Disponível em: <<http://dx.doi.org/10.1109/WF-IoT.2015.7389136>>. Citado na página 21.

ZHANG, C. et al. Smart home design based on ZigBee wireless sensor network. In: *7th International Conference on Communications and Networking in China*. Institute of Electrical & Electronics Engineers (IEEE), 2012. Disponível em: <http://dx.doi.org/10.1109/ChinaCom.2012.6417527>. Citado na página 21.

ZHOU, B. et al. Smart home energy management systems: Concept, configurations, and scheduling strategies. *Renewable and Sustainable Energy Reviews*, Elsevier BV, v. 61, p. 30–40, aug 2016. Disponível em: <http://dx.doi.org/10.1016/j.rser.2016.03.047>. Citado na página 19.