

UNIVERSIDADE FEDERAL DO AMAZONAS
INSTITUTO DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

**Economia de Energia Elétrica em Ambientes Inteligentes Baseada no
Reconhecimento de Atividades do Usuário**

Wesllen Sousa Lima

Manaus - Amazonas
Março de 2015

Wesllen Sousa Lima

Economia de Energia Elétrica em Ambientes Inteligentes Baseada no Reconhecimento de Atividades do Usuário

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Informática da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Informática.
Área de concentração: Redes de Computadores.

Orientador: Prof. Dr. Eduardo James Pereira Souto

Ficha Catalográfica

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

S725e Sousa Lima, Wesllen
Economia de Energia Elétrica em Ambientes Inteligentes
Baseada no Reconhecimento de Atividades do Usuário / Wesllen
Sousa Lima. 2015
90 f.: il.; 297 cm.

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

1. Ambiente Inteligente. 2. Economia de Energia. 3. Reconhecimento de Atividades. 4. Algoritmo de Recomendação. I. Souto, Eduardo James Pereira II. Universidade Federal do Amazonas III. Título

*Dedico esta dissertação aos meus pais
Que sempre estiveram ao meu lado me ajudando.
Amo vocês!*

Agradecimentos

Querido Deus, desta vez não quero pedir. Quero somente agradecer! Obrigado pelas bênçãos, pelas promessas cumpridas, por ter me dado sabedoria para me livrar do mal e superar os obstáculos da vida e, especialmente, por me ter feito chegar até aqui e concluir mais esta fase da minha vida. Obrigado por tudo, não tenho palavras para agradecer!

Existem coisas na vida em que não conseguimos expressar com palavras, apenas o coração sabe explicar o que sentimos. É desta forma que me sinto todas as vezes que tento agradecer os meus pais. Eles nunca medem esforços para ajudar seus filhos, mesmo nos momentos em que não há condições para isso. Sou constantemente grato pelas orações, pelos conselhos, pelos incentivos, (...). Sem ajuda de vocês essa conquista não seria possível. Agradeço do fundo do meu coração. Obrigado, Amo vocês!

Também gostaria de expressar minha sincera gratidão pelo meu orientador, Eduardo Souto. Obrigado por ter me aceitado como seu aluno e por ter me ajudado a adquirir este título de mestre. Eu gostaria de dizer que você é um orientador paciente, atencioso, motivador e o mais importante de tudo uma pessoa amiga. Eu particularmente acho você um exemplo a ser seguido, tanto profissionalmente quanto como pessoa mesmo 😊. Obrigado por tudo, me sinto muito honrado em ser seu aluno.

Agradeço a irmã Evanir, a Keila e o Alexandre por ter me acolhido e me dado todo apoio aqui em Manaus durante todo o curso. Quero agradecer especialmente a irmã Evanir que faz o papel de mãe, já considero a senhora como integrante da minha lista de mães adotivas 😊. Muito obrigado!

Agradeço a todos os meus amigos que estiveram comigo durante o mestrado. Alguns eu já conhecia outros eu fui conhecendo ao longo do tempo. Durante este período fiz boas amizades e conheci pessoas maravilhosas tanto dentro quanto fora da universidade. Não vou listar os nomes aqui porque corre o risco de eu esquecer alguém, mas cada um sabe quem vocês são. Muito obrigado pelo companheirismo, Valeu pessoal! 😊

Agradeço a todos que contribuíram diretamente ou indiretamente para realização deste trabalho. Mesmo aqueles que ajudaram na última hora como é o caso da Thalita que

fez a revisão final desta dissertação. Também quero agradecer a professora Eulanda e a professora Judith por fazer parte da banca de avaliação. A todos, meus sinceros agradecimentos.

Agradeço ao programa de pós graduação do Instituto de computação (IComp) da Universidade Federal do Amazonas (UFAM) pela oportunidade e suporte que tem dado a todos os alunos. Me sinto grato por participar de um programa de pós-graduação de qualidade que a cada dia vem conquistando seu espaço perante as outras universidades. Parabéns professores e alunos. Também agradeço o pessoal da secretaria que estão sempre prontos para resolver qualquer problema, especialmente a Elienai.

Por fim, não posso deixar de agradecer Capes pelo apoio financeiro que me deu durante o mestrado.

A mente que se abre a uma nova ideia jamais
volta ao seu tamanho original.

Albert Einstein

Resumo

Nos últimos anos, o consumo de energia elétrica tem aumentado gradativamente em todos os setores, especialmente em ambientes residenciais. Esse aumento ocorre, principalmente, devido ao surgimento de novos aparelhos elétricos. Por este motivo, várias soluções têm sido propostas pelo governo e pela indústria na tentativa de minimizar o consumo de energia elétrica em residências. Dentre as abordagens propostas, destacam-se a conscientização das pessoas, uso de fontes de energia renováveis e a criação de aparelhos inteligentes. Além disso, o uso de Tecnologias da Informação e Comunicação (TICs) em ambientes inteligentes tem sido visto como uma alternativa interessante para lidar com este problema. A ideia é que as residências sejam instrumentadas com sensores e atuadores com objetivo de monitorar as atividades das pessoas e, por meio disso, gerenciar o consumo de energia elétrica com base nos seus hábitos.

Nesse contexto, este trabalho propõe e valida um método capaz de economizar energia com base nas atividades dos usuários em um ambiente inteligente utilizando técnicas de inteligência artificial. O objetivo é identificar os aparelhos relacionados às atividades dos usuários e fazer recomendações ao longo da execução dessas atividades, evitando tais desperdícios. O método proposto, denominado de AAEC (*Activity-Appliance-Energy Consumption*), é capaz de analisar um conjunto de dados coletados pelos sensores disponíveis no ambiente, reconhecer automaticamente as atividades dos usuários e recomendar ações que visam a contenção de gastos. Testes feitos com uma base de dados real mostram que o método proposto é capaz de economizar até 35% de energia elétrica. De maneira geral, a inclusão do método AAEC se mostrou uma boa solução para auxiliar as pessoas a poupar energia sem que haja esforço na mudança de comportamento do indivíduo, contribuindo para o uso consciente de energia e no desenvolvimento de uma sociedade sustentável.

Palavras chaves - Ambiente Inteligente, economia de energia, reconhecimento de atividades.

Abstract

In recent years, power consumption has gradually increased in all sectors, especially in residential areas. This increase is mainly due to the emergence of new electrical appliances, for this reason, several solutions have been proposed by government and industry in order to minimize the energy consumption in homes. Among the proposed approaches, people's awareness, use of renewable energy sources and the creation of intelligent devices are highlighted. In addition, the use of Information and Communication Technologies (ICTs) in smart environments has been seen as an interesting alternative to deal with this problem. The idea is that the residences are instrumented with sensors and actuators in order to monitor people activities and, thereby, manage the power consumption based on their habits.

In this context, this work proposes and validates a method to save energy through user activities in an intelligent environment using artificial intelligence techniques. The goal is to identify the devices related to user activities and make recommendations during their execution, avoiding waste. The proposed method, called AAEC (Activity-Appliance-Energy Consumption), is able to analyze a set of data collected from sensors available in the environment, after it recognizes user activities and recommends actions aimed at cost containment. Tests on a real database shown that the proposed method is able to save up to 35% of electricity. In general, the inclusion of AAEC method was a good solution to help people save energy without effort on individual behavior changes, contributing to the conscious use of energy and to the development of a sustainable society.

Key words – smart environment, energy saving, activity recognition

Sumário

Introdução	14
1.1. MOTIVAÇÃO	16
1.2. OBJETIVO	17
1.3. CONTRIBUIÇÕES	17
1.4. ORGANIZAÇÃO DA DISSERTAÇÃO	18
Fundamentação Teórica	19
2.1. INTERNET DAS COISAS	19
2.2. ECONOMIA DE ENERGIA ELÉTRICA	20
2.3. RECONHECIMENTO DE ATIVIDADE	22
2.3.1. Processo de Reconhecimento de Atividade	23
2.3.2. Métodos e Técnicas de Reconhecimento de Atividade	24
2.4. RELAÇÃO ENTRE RECONHECIMENTO DE ATIVIDADE E ECONOMIA DE ENERGIA	26
2.4.1. Algoritmos de Ranqueamento	28
2.4.2. Modelo Vetorial	29
Trabalhos Relacionados	33
3.1. CONSUMO DE ENERGIA E RECONHECIMENTO DE ATIVIDADES	33
3.1.1. Context-aware Home Energy Saving based on Energy-Prone Context	33
3.1.2. Integration of IoT Energy Management System with Appliance and Activity Recognition	35
3.1.3. Appliance Recognition and Unattended Appliance Detection for Energy Conservation	35
3.2. ECONOMIA DE ENERGIA	37
3.2.1. A Location-Aware Lifestyle Improvement System to Save Energy in Smart Home ...	37
3.2.2. A semantic Representation of Energy-Related Information in Future Smart Homes	38
3.2.3. OWL Ontologies and SWRL Rules Applied to Energy Management	39
3.2.4. A Decision Tree Method for Building Energy Demand Modeling	40
3.3. RECONHECIMENTO DE ATIVIDADES	41
3.3.1. Online Activity Recognition Using Evolving Classifiers	41
3.3.2. Recognizing Independent and Joint Activities Among Multiple Residents in Smart Environments	41

3.3.3. Development of Context Aware System based on Bayesian Network Driven Context Reasoning Method and Ontology Context Modeling	42
3.4. DISCUSSÕES.....	43
Método Proposto	46
4.1. VISÃO GERAL	46
4.2. MODELAGEM DE PROCESSOS DO MÉTODO AAEC.....	47
4.2.1. Coleta de Dados dos Sensores	49
4.2.2. Coleta do Consumo de Energia	50
4.2.3. Reconhecimento de Atividade	50
4.2.4. Relação entre Atividade e Aparelho	53
4.2.5. Recomendação de ações	56
4.2.6. Detalhamento dos Algoritmos	58
4.3. CONSIDERAÇÕES FINAIS.....	60
Experimentos e Resultados.....	62
5.1. PROTOCOLO EXPERIMENTAL	62
5.1.1. Cenário	62
5.1.2. Detalhamento da Base de Dados	65
5.1.3. Métricas	69
5.2. RESULTADOS	71
5.2.1. Comparação dos Algoritmos de Aprendizagem	71
5.2.2. Economia de Energia	73
5.3 CONSIDERAÇÕES FINAIS.....	77
Considerações Finais e Trabalhos Futuros	78
6.1 CONSIDERAÇÕES FINAIS.....	78
6.2. TRABALHOS FUTUROS.....	79
Referências	81

Lista de Abreviações

AAEC – Activity Appliance Energy Consumption
ADL – Activity Daily Living
AI – Artificial Intelligence
AM – Aprendizagem de máquina
Aml – Ambient Intelligent
API – Application Programming Interface
BAL – Building
BPM – Business Process Model
BPMN – Business Process Model and Notate
DA – Dynamic avaluation
DAL – District
EPC – Energy-Prone Context
eEPC - Extended Event-driven Process Chain
HAL – Home
HEMS - Home Energy Management System
HNN - Hidden_Markov_Model
HVAC - heating, ventilation, and air conditioning
ID3 - Iterative Dichotomiser 3
IDE – Intelligent Domotic Environment
IDF – Inverse Document Frequency
IoT – Internet of Things
KNN - k-Nearest Neighbors
kWh – Kilowatts por hora
MAS - mult-agents systems
M2M – Machine to Machine
OWL - Web Ontology Language
RDF - Resource Description Framework
RI – Recuperação de Informação
SQWRL - Semantic Web Rule Language
SHO - Smart Home Ontology
SHS – Smart Home System
SQL - Structured Query Language
SVM – Suport Vector Machine
UML - Unified Modeling Language
WoD - Web of Domotics
WSN – Wireless sensors networks

Lista de Figuras

Figura 2.1. Casa inteligente com sensores de corrente elétrica. Fonte.....	22
Figura 2.2. Representação gráfica vetorial em que os vetores de documento e expressão das consultas são representados.....	30
Figura 2.3. Gráfico representando a curva do IDF.	31
Figura 3.1. Um exemplo do modelo EPC como uma representação gráfica.....	34
Figura 3.2. Exemplo de diagrama de blocos baseados no tempo. Cada bloco representa uma atividade sendo executada em um tempo T enquanto os aparelhos D estão em execução. Este período forma blocos B's menores que são períodos utilizados para identificar uma atividade.	35
Figura 3.3. Exemplo de aparelhos vinculados à atividade 'Usando computador'. Os tamanhos das bolinhas indicam o nível de relação dos aparelhos com a atividade.	36
Figura 3.4. Regras de um modelo ontológico para energia. Essa Figura mostra um exemplo de atuação de um dispositivo controlável no modelo da arquitetura DogOnt.	39
Figura 3.5. Árvore de decisão que prevê o nível de EUI dos prédios. Os dados contidos na árvore são o número do nó, dados gravados nesse nó, entropia, teste de corte e atributos de classificação (folha).	40
Figura 3.6. Exemplo de atividades representadas na cadeia escondida de Markov. Os círculos apresentam estados escondidos ou atividades e os retângulos representam os estados visíveis. As arestas representam as transições com as probabilidades.	42
Figura 3.7. Estrutura das redes bayesianas para inferência de atividade.....	43
Figura 4.1. Visão geral do método AAEC.....	46
Figura 4.2. Modelo do processo de negócios da proposta.	49
Figura 4.3. Processo de coleta de dados das redes de sensores.	50
Figura 4.4. Processo de medição do consumo dos aparelhos.	50
Figura 4.5. Processo de negócio do reconhecimento de atividade.	51
Figura 4.6. Exemplo representativo da árvore de decisão.....	51
Figura 4.7. Processo de negócio do relacionamento entre atividade e aparelho.	53
Figura 4.8. Processo de recomendação de ações por meio de algoritmos de recomendação.....	56
Figura 5.1. Fotos de alguns locais onde os sensores estão instalados no apartamento.	63
Figura 5.2. Mapa do apartamento.	64
Figura 5.3. Porcentagem das categorias de atividades encontradas na base MIT.	68
Figura 5.4. Consumo de cada aparelho.....	69
Figura 5.5. Árvore de decisão para reconhecimento de categoria de atividades.....	72
Figura 5.6. Consumo de cada atividade sendo executada no horário de pico.	75
Figura 5.7. Período de realização das atividades no dia 30 de março de 2003.	76
Figura 5.8. Consumo de energia com e sem o método AAEC no domingo do dia 30/03.	76

Lista de Tabelas

Tabela 3.1. Tipo de aparelhos. Classificação de aparelhos que necessitam ou não de ficar ligados na presença do usuário e também se é possível prever o tempo em que os aparelhos ficaram ligados.	37
Tabela 3.2. Comparação dos trabalhos relacionados.	44
Tabela 4.1. Principais elementos básicos de modelagem da linguagem BPMN 2.0.	48
Tabela 4.2. Exemplo das atividades da categoria 'Cozinhar', executada na cozinha. O tempo de execução do sensor está mais próximo de 'Preparar bebida'.	52
Tabela 4.3. Organização dos dados por meio de uma lista invertida.	54
Tabela 4.4. Exemplo do ranqueamento de atividades para uma consulta de aparelhos ligados.	54
Tabela 4.5. Exemplo de ranqueamento de objetos associados a uma atividade.	56
Tabela 4.6. Exemplos de aparelhos elétricos separados por categorias.	57
Tabela 4.7. Tipos dos aparelhos.	58
Tabela 5.1. Disposição dos sensores no apartamento.	64
Tabela 5.2. Detalhe dos dados de cada atributo.	66
Tabela 5.3. Atividades com suas respectivas categorias.	67
Tabela 5.4. Algoritmos de aprendizagem usados no reconhecimento das categorias das atividades.	71
Tabela 5.5. Previsão mensal de consumo dos aparelhos elétricos.	73
Tabela 5.6. Consumo de energia total das atividades para os cenários com e sem o método AAEC.	74

Capítulo 1

Introdução

A Internet das Coisas (do inglês, Internet of Things - IoT) é um novo paradigma que surgiu com objetivo de integrar e conectar objetos (sensores, aparelhos elétricos, dispositivos móveis, etc) para melhorar a qualidade de vida das pessoas [C. Perera et al. 2013]. Esse conceito tem sido empregado para fomentar o desenvolvimento de Cidades Inteligentes (do inglês, Smart Cities) por meio do emprego de tecnologias da informação e comunicação (TICs).

Tornar uma cidade “inteligente” tem sido visto como uma estratégia para minimizar os problemas gerados pelo explosivo crescimento da população em áreas urbanas. Assim, a instrumentação das cidades com sistemas de informações complexos tem sido visto como a melhor alternativa para integrar a operação dos serviços e infraestruturas urbanas como construções, transporte, distribuição de energia e água, saúde e segurança pública [Harrison et al., 2011].

O uso eficiente dos recursos energéticos tem recebido uma atenção particular, visto que na maioria dos países a produção de energia depende de recursos naturais esgotáveis. Nos EUA, por exemplo, a agência internacional de energia (IEA) estima que o consumo de energia continuará crescendo cerca 25% entre 2010 e 2020 [S. Tompros et al., 2009]. No Brasil, este consumo vem aumentando gradativamente. Em 2012, o país consumiu 448.1 TWh, valor 3,5% acima do consumido em 2011 [EPE, 2013].

Na tentativa de tornar o uso de energia elétrica mais eficiente, entidades governamentais e a indústria têm empregado um conjunto de ações visando minimizar o consumo de energia, dentre as quais se destacam: i) A conscientização da sociedade em criar bons hábitos de consumo; ii) A utilização de fontes de energia alternativas e renováveis como, por exemplo, energia eólica, solar, biogás e geotérmica; e iii) A criação de aparelhos

doméstico com funcionalidades para minimizar o consumo de energia como as smart TVs e as geladeiras inteligentes.

Além dessas ações, a instrumentação de ambientes com sensores, atuadores e outros dispositivos conectados em rede também tem ganhado muito destaque nos últimos anos. A ideia básica por trás desses ambientes inteligentes (do inglês, Ambient Intelligence - Aml) [C. Ramos, 2008] é que, o enriquecimento de um ambiente com TICs possibilita o desenvolvimento de sistemas de gerenciamento e controle baseados nas informações em tempo real e no histórico dos dados acumulados.

Nesse contexto, sistemas de gerenciamento de energia doméstica (do inglês, Home Energy Management System - HEMS) [Khan, 2013] têm sido propostos para dirigir e controlar a infraestrutura elétrica e os eletrodomésticos em uma residência. No entanto, a maioria das soluções existentes é projetada com escopo limitado, tais como controle de iluminação com detecção de movimento, controle do clima com base na temperatura interna do ambiente, e controle para ligar e desligar aparelhos elétricos.

Por outro lado, as atividades desenvolvidas pelos usuários têm impacto considerável na quantidade de energia consumida em ambientes residenciais. C. F. Lai et al. [2012] afirmam que o consumo de energia dos aparelhos elétricos está diretamente ligado às atividades humanas e que uma quantidade significativa de energia poderia ser economizada se os aparelhos se ajustassem de acordo com as necessidades reais dos usuários.

Este trabalho especifica um novo método, denominado AAEC (Activity-Appliance-Energy Consumption), capaz de reconhecer as atividades dos usuários com base na relação atividade/aparelhos e recomendar ações para evitar desperdícios de energia elétrica. O método proposto emprega um algoritmo de árvore de decisão para gerar um modelo capaz de reconhecer automaticamente as atividades desenvolvidas pelo usuário e um algoritmo de ranqueamento usado para definir a importância de cada aparelho em relação à determinada atividade. Os resultados dos experimentos baseados em dados reais obtidos no projeto MIT (Massachusetts Institute Technology) para reconhecimento de atividades em ambientes residenciais [E. M. Tapia, 2004] mostram uma economia média de 35% no consumo de energia, comprovando a viabilidade da utilização do método AAEC em ambientes reais.

1.1. MOTIVAÇÃO

O reconhecimento das atividades dos usuários tem sido empregado para múltiplos propósitos, incluindo monitoramento de pessoas idosas [B. Najafi et al., 2003], auxílio de pessoas com deficiência mental [APA, 1994], controle de casas inteligentes [Vázquez et al., 2011], atividades esportivas [M. Ermes, 2008] e outros. Recentemente algumas pesquisas têm sido desenvolvidas visando fornecer meios para economizar energia com base na relação entre atividades e aparelhos elétricos [Z. Cheng and Y. Ozawa, 2012] [M. Weng et al., 2012][C. F. Lai et al., 2012][S. Lee, 2010]. Entretanto, os resultados mostram que as pesquisas nessa área ainda estão em seu estágio inicial, pois identificar padrões de consumo e desperdícios de energia observando o comportamento dos usuários não é uma tarefa trivial, visto que, as pessoas possuem estilos de vida diferentes e suas atividades mudam com o passar do tempo.

A verificação destas atividades é uma solução relevante para evitar tais desperdícios, como também ajudar na preservação de recursos naturais de forma indireta. Neste contexto, o uso de TICs tem ajudado na manipulação de informações físicas de um ambiente por meio dos sensores e atuadores, possibilitando o desenvolvimento de sistemas computacionais capazes de capturar a interação entre o ambiente e as atividades dos usuários.

Entretanto, estabelecer a relação entre aparelhos e atividades de forma automática não é simples. A solução proposta deve se preocupar com nível de importância que cada aparelho possui com a atividade que está sendo executada. Além disso, um aparelho pode estar envolvido diretamente com mais de uma atividade. Em geral, esse nível de importância é determinado pela frequência dos aparelhos nas atividades e pode ser obtido de diferentes formas [M. Weng et al., 2012] [C. F. Lai et al., 2012] [S. Lee et al., 2012].

Para tratar esse problema, este trabalho propõe o uso de um modelo vetorial [OLIVEIRA 2007], muito utilizado na área de recuperação de informação, para estabelecer relação entre atividade e aparelho de forma consistente.

1.2. OBJETIVO

A necessidade de instrumentação de ambientes com sensores e atuadores e o desenvolvimento de programas que visam aprimorar as atividades diárias das pessoas tornando o ambiente cada vez mais confortável tem sido cada vez mais comum.

Nesse contexto, este trabalho desenvolve e valida um método capaz de minimizar o consumo de energia elétrica em residências por meio da relação entre a atividade desenvolvida pelo usuário e aparelhos elétricos associados à atividade.

Para alcançar o objetivo geral dessa pesquisa, um conjunto de objetivos específicos devem ser alcançados, dentre os quais destacam-se:

- Desenvolvimento de um algoritmo para reconhecer as atividades do usuário utilizando classificadores baseados em árvore de decisão;
- Construção de um algoritmo de ranqueamento que define a importância de cada aparelho em relação à determinada atividade utilizando o modelo de espaço vetorial;
- Construção de um algoritmo para recomendar ações que minimizam o consumo de energia, levando em consideração os aparelhos envolvidos durante sua execução.

1.3. CONTRIBUIÇÕES

Esta pesquisa alcança as seguintes contribuições científicas:

- Um algoritmo que identifica as possíveis atividades através da análise dos aparelhos em operação. Utilizando modelo vetorial, o algoritmo proposto define níveis de importância (rank) de cada atividade em relação a um conjunto de aparelhos. A contribuição está na aplicação do modelo vetorial em um cenário diferente, pois comumente este modelo é aplicado na área de recuperação da informação. Neste cenário, as atividades são equivalentes aos documentos e os aparelhos aos termos do documento.
- Um algoritmo que ranqueia os aparelhos de uma determinada atividade. O objetivo é definir o nível de importância dos aparelhos relacionados a uma atividade a partir da análise da frequência de utilização destes aparelhos em

outras atividades. A contribuição está no algoritmo de ranqueamento proposto neste trabalho.

- Um mecanismo capaz de recomendar ações com base nos tipos de aparelhos, levando em consideração a necessidade de presença do usuário e a capacidade de prever o tempo dos aparelhos em operação. A contribuição está no mecanismo que trata e recomenda diferentes ações de acordo com os tipos de aparelhos.

1.4. ORGANIZAÇÃO DA DISSERTAÇÃO

O Capítulo 2 trabalha os principais conceitos e ferramentas utilizadas nesta pesquisa, fornecendo informações necessárias para o entendimento da proposta. Os conceitos estão divididos em grupos separados por áreas e estão postos de forma a facilitar o entendimento do método AAEC.

O Capítulo 3 apresenta os trabalhos correlatos, onde são divididos em dois grupos: reconhecimento de atividade e economia de energia. É relevante enfatizar que o reconhecimento de atividade e trabalhos de economia de energia são áreas de pesquisas diferentes. Logo, é comum que esses assuntos sejam tratados separadamente. Entretanto existem trabalhos que utilizam ambas as áreas, propondo uma solução de economia de energia baseada na atividade do usuário.

O Capítulo 4 apresenta a proposta dessa pesquisa dividida em duas partes: A primeira mostra uma visão geral do método AAEC por meio de uma arquitetura e a segunda apresenta detalhes do método modelado na linguagem BPMN.

O Capítulo 5 descreve o projeto e a implementação do método AAEC. Todos os processos são mostrados na prática sobre uma base de dados real com a aplicação dos algoritmos desenvolvidos. Em seguida, são expostos os resultados do método AAEC, envolvendo testes com a árvore de decisão e o quanto o método economizou energia no cenário de teste.

Por fim, o Capítulo 6 apresenta as considerações finais do trabalho, destacando as contribuições e os resultados obtidos com o método AAEC. Também serão sugeridos trabalhos futuros que podem melhorar o método AAEC com adição de novas funcionalidades.

Capítulo 2

Fundamentação Teórica

Este capítulo introduz os conceitos e as definições necessárias para o entendimento deste trabalho. A primeira seção apresenta os conceitos e características de Internet das coisas e a sua relação com ambientes inteligentes. A segunda seção faz uma breve descrição sobre a área de economia de energia e sistemas de gerenciamento de energia para casas inteligentes (HEMS). O HEMS é projetado para monitorar e gerenciar o consumo de aparelhos domésticos em ambientes inteligentes. A terceira seção apresenta os processos, métodos e técnicas desenvolvidos para reconhecer atividades. A quarta seção descreve o relacionamento entre a área de reconhecimento de atividade e a área de economia de energia, bem como o modelo de ranqueamento, denominado de modelo vetorial, utilizado neste trabalho para determinar o nível de importância de um aparelho em uma determinada atividade.

2.1. INTERNET DAS COISAS

Esta seção explica um breve resumo do novo paradigma da Internet das coisas (do inglês, *Internet of Things - IoT*). Não é objetivo deste trabalho fornecer detalhes sobre a IoT, somente o suficiente para o entendimento da solução e o uso desse conceito dentro de ambientes inteligentes.

A IoT ainda não possui um conceito bem definido, vários trabalhos definem IoT de diferentes formas [P. Guillemin and P. Friess, 2009][K. Ashton, 2009][T. Lu and W. Neng, 2010][European Commission, 2008], mostrando que a área ainda está dando seus passos iniciais. Embora existam vários conceitos, todos convergem para o mesmo sentido e um dos conceitos mais aceitos pela comunidade científica é o proposto por Guillemin and Friess [2009]:

“A Internet das coisas permite pessoas e coisas serem conectadas a qualquer hora em qualquer lugar, utilizando qualquer rede ou serviço”.

A ideia básica deste conceito está na variedade de “coisas” ou “objetos” que estão interconectados por modernas tecnologias de telecomunicação tais como identificação por rádio frequência (do inglês, *Radio-Frequency Identification - RFID*), sensores, atuadores, dispositivos móveis, pilhas de protocolos, web semântica, processamento de dados, comunicação, etc. Tais tecnologias são capazes de interagir entre si e colaborar com seus vizinhos para alcançar um objetivo comum [L. Atzori et al., 2010].

Dentre as tecnologias citadas, as redes de sensores (do inglês, *Sensor Network*) [J. Yick, 2008] têm uma forte relação com IoT, por isso são consideradas um componente essencial. Uma rede de sensores é um conjunto de nós sensores que se conectam e comunicam entre si por meio de cabos ou tecnologias sem fio [C. Perera et al., 2013]. Atzori et al. [2010] consideram as redes de sensores com uma ponte do mundo real para o mundo virtual, pois os sensores são capazes de informar a um computador a situação de um ambiente físico, propiciando possibilidades de ações diversas com base nas informações extraídas do ambiente.

A capacidade de extrair informações do ambiente físico por meio dos sensores e a implementação de uma camada de inteligência para tratamento e decisão dos dados, possibilitam a criação de ambientes inteligentes (do inglês, *Ambient Intelligent - Aml*). Perera et al. [2013] definem Aml como sendo um ambiente digital proativo e sensível que dá suporte diário às atividades das pessoas. O Aml é uma combinação de diferentes tecnologias que coletam informações do ambiente físico e geram conhecimento através de um processamento computacional, reagindo a estímulos do usuário de forma transparente. Neste contexto, Aml pode ser aplicado em diferentes domínios, como: transporte e logística [S. Karpischek et al., 2009], saúde [C. Buckl et al., 2009], automação de ambientes (casa, escritório, prédios) [Khan et al., 2013] e social [E. Welbourne et al., 2009]. A solução proposta neste trabalho está focada no domínio de automação de ambientes residenciais, cujo objetivo é economizar energia com base no comportamento dos usuários.

2.2. ECONOMIA DE ENERGIA ELÉTRICA

O aumento no emprego de TICs para automação de ambientes nos últimos anos tem se tornado cada vez mais evidente. Prédios, casas e escritórios inteligentes que controlam as

luminárias ou customizam a temperatura do ambiente, estão se tornando cada vez mais comuns. O estímulo da criação de ambientes inteligentes se dá principalmente pela redução de custos e a diversidade de tecnologias de sensoriamento e comunicação existentes.

A diversidade de tecnologias traz a possibilidade de monitorar o consumo de energia elétrica por meio de sensores e atuadores, abrindo portas para o desenvolvimento de sistemas capazes de economizar energia. Sensores de presença, temperatura e umidade podem ser utilizados para fornecer dados necessários para ajustar automaticamente o nível de conforto em um ambiente e aperfeiçoar o uso de energia das diversas fontes consumidoras, por exemplo, aparelhos eletrodomésticos.

Estes sistemas de monitoramento e controle de consumo de energia são comumente denominados de Sistema de Gerenciamento de Energia. No contexto de ambientes residenciais, tais sistemas são designados como *Home Energy Management System (HEMS)*.

Kailas et al. [2012] definem HEMS como sendo um sistema computacional que monitora, controla e economiza energia dentro de uma residência. Khan et al. [2013] listam as seguintes possibilidades de aplicação do HEMS: monitorar o tempo de uso dos aparelhos, o consumo no horário de pico, exibir valor atual do consumo de energia, fazer previsão de consumo, etc.

Dentro de uma casa, os consumidores de energia são os aparelhos domésticos. O HEMS monitora o consumo de energia desses aparelhos por meio de sensores de corrente elétrica, geralmente denominados de medidores inteligentes (do inglês, *smart meters*). Os dados obtidos desses sensores costumam ser enviados para um *gateway* e posteriormente são tratados pelo HEMS [D. Niyato et al., 2011]. A Figura 2.1 mostra uma visão geral de uma casa inteligente com sensores de corrente elétrica.

Diante desse contexto, este trabalho cria um método que economiza energia por meio do reconhecimento das atividades dos usuários com base na análise dos dados oriundos dos sensores. Tal método pode ser implementado como um módulo adicional aos HEMS existentes, acrescentando mais uma funcionalidade útil para economizar energia. Além disso, o capítulo 4 mostra o processo de economia de energia com base nas categorias de aparelhos elétricos definidas inicialmente por Niyato et al. [2011].

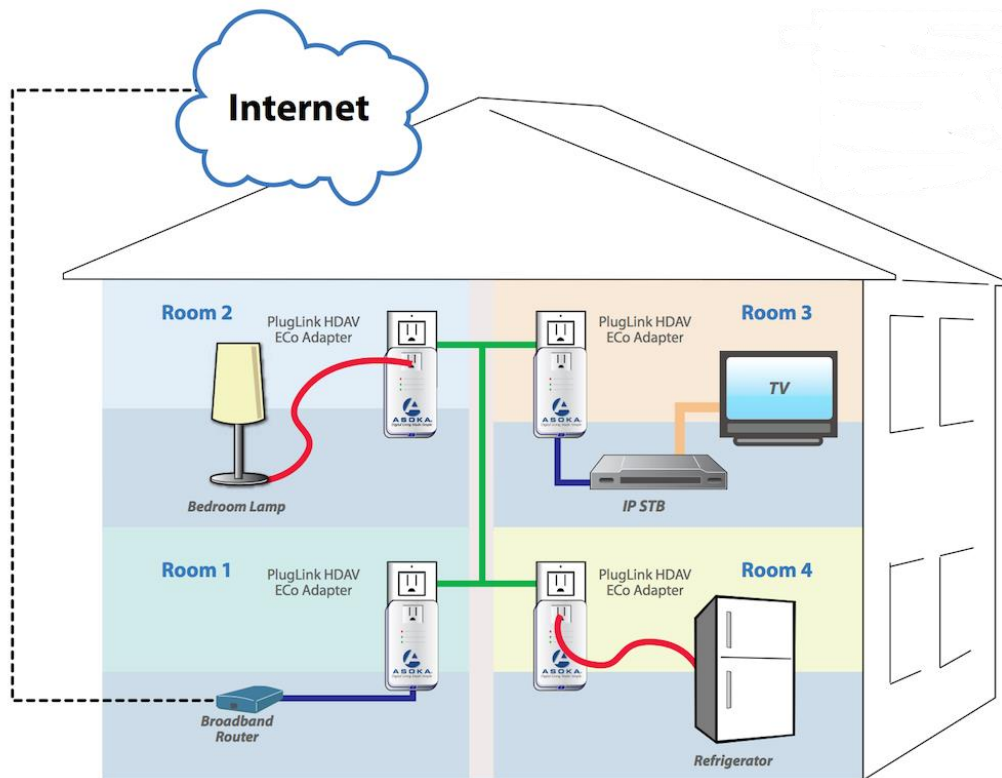


Figura 2.1. Casa inteligente com sensores de corrente elétrica. Fonte¹.

2.3. RECONHECIMENTO DE ATIVIDADE

O ser humano realiza dezenas de atividades por dia, como tomar banho, assistir televisão, cozinhar, dormir, etc. O conhecimento e controle dessas atividades ajudam a resolver problemas de vários domínios do dia a dia, por exemplo, monitoramento de pessoas idosas [Osmani et al., 2008], automação residencial [G. Singla et al., 2010], economia de energia [C. F. Lai et al., 2012] entre outras. Portanto, com a evolução dos Aml e a possibilidade de aplicação de técnicas de inteligência artificial, permitem que tais atividades sejam reconhecidas automaticamente.

O reconhecimento de atividades humanas é abordado de diferentes formas. Tapia [2003] afirma que alguns trabalhos fazem análises complexas de sinais de sensores, por exemplo, sensor presença, vídeos de câmeras e áudio de microfones e outros trabalhos utilizam RFID para reconhecer atividades. O reconhecimento de atividades por meio de sensores ainda é um desafio, pois a extração de características dos sinais e o

¹<http://www.asokatech.com/home-energy-management>

reconhecimento de padrões por meio de algoritmos de aprendizagem de máquina ainda é uma tarefa complexa devido à diversidade de cenários.

Para facilitar os estudos, Ordóñez et al. [2013] dividem o processo de reconhecimento de atividade em duas classes:

- i) **Primeira classe:** trata do reconhecimento da atividade dentro de um Aml por meio de sensores [JehadSarkar et al., 2010][Cook et al., 2009];
- ii) **Segunda classe:** trata do reconhecendo atividades utilizando a computação vestível (do inglês, *wearable computing*) [U. Maurer et al., 2006].

Este trabalho foca na primeira classe, devido o objetivo ser economizar energia dentro de um Aml. O reconhecimento de atividade da primeira classe obedece a um conjunto de etapas bem definidas. Com base nisso, Brgulja et al. [2010] criou um *framework* que encapsula essas etapas em um único processo. A próxima seção aborda as etapas do processo de reconhecimento de atividade nos ambientes inteligentes propostos pelo *framework*.

2.3.1. Processo de Reconhecimento de Atividade

Brgulja et al. [2010] propôs um *framework* para reconhecimento de atividade que utiliza técnicas de aprendizagem de máquina e mineração de dados. A arquitetura do *framework* é formada pelos seguintes elementos: coleta de dados, extração de características, anotação de dados e reconhecimento de atividade.

Coleta de dados: É a primeira etapa do processo, que é dada por meio de sensores, atuadores e/ou RFID. Essa etapa requer detalhamento do ambiente onde os dados foram coletados bem como dos dispositivos envolvidos.

Extração de característica: Esta etapa é responsável por extrair características dos dados para montar a base que servirá como entrada para os algoritmos de aprendizagem de máquina. Por exemplo: tempo de ativação do sensor, horário que a ação foi realizada, sensores envolvidos e consumo de energia por cada ação.

Anotação dos dados: Os dados são rotulados para posteriormente serem utilizados por um algoritmo de aprendizagem de máquina. As atividades são vinculadas a

determinados sensores e o algoritmo de classificação prevê qual atividade está sendo executada.

Reconhecimento de atividade: Depois dos dados organizados e as características bem definidas, a próxima etapa é aplicar as técnicas definidas para o reconhecimento de atividade.

Durante os estudos, foi observado que esse processo é seguido por todos os trabalhos que utilizam técnicas de aprendizagem de máquina. A diferença entre os trabalhos está apenas na aplicação de diferentes técnicas, a próxima seção aborda com mais detalhes as técnicas utilizadas em alguns trabalhos de reconhecimento de atividade.

2.3.2. Métodos e Técnicas de Reconhecimento de Atividade

O reconhecimento de atividades humanas pode ser implementada utilizando várias técnicas, por exemplo, lógica simples [Z. Cheng and Y. Ozawa, 2012], lógica *fuzzy* [F. J. Ordóñez et al., 2013], ontologias [G. Meditskos et al., 2013] entre outras. Além disso, as técnicas de aprendizagem de máquina também se mostraram bastante eficientes, devido à possibilidade de criação de modelos específicos para diversos cenários utilizando apenas um algoritmo. As técnicas mais comuns utilizadas nos trabalhos de reconhecimento de atividade são as redes bayesianas [C. F. Lai et al., 2012][K. Ko and K. Sim, 2008], cadeias escondidas de *markov* [G. Singla et al., 2010] e árvores de decisão [N. Brgulja et al., 2010].

O método escolhido para reconhecimento de atividade nessa pesquisa foi a árvore de decisão. O motivo da escolha é que este método possui uma maior acurácia em relação aos outros métodos do contexto de reconhecimento de atividade, como mostra pesquisa feita por Huang et al. [2008] e também pelos próprios testes de comparação feitos neste trabalho.

Mas antes de explicar o funcionamento da árvore de decisão é importante introduzir conceitos básicos de aprendizagem de máquina para melhor entendimento da aplicabilidade do método em relação à resolução do deste problema.

2.3.2.1. Aprendizagem de Máquina

Aprendizagem de máquina (AM) é uma subárea da inteligência artificial responsável pela criação de técnicas e algoritmos capazes de ensinar o computador a aprender com os dados [Katti Faceli et al., 2011]. Segundo Mitchell [Mitchell, 1997] AM é: “A *capacidade de*

melhorar o desempenho na realização de alguma tarefa por meio da experiência.”. Assim, a AM permite que os computadores aprendam determinado conhecimento através de um histórico de dados representativo.

A capacidade de aprendizado de uma máquina se baseia em uma hipótese de indução que pode ser generalizada para todo um conjunto dos dados. O objetivo dos algoritmos de AM é aprender, a partir de um subconjunto de dados denominado conjunto de treinamento, um modelo capaz de reconhecer as saída dos atributos do subconjunto de treinamento com os atributos do conjunto de dados [Katti Faceli et al., 2011].

Cada algoritmo de AM possui um viés indutivo para representar a hipótese, ou seja, cada algoritmo tem uma forma de representação diferente. Um algoritmo de árvore de decisão, por exemplo, possui uma representação na qual os nós internos representam uma pergunta e os nós externos estão associados a uma classe ou atributo alvo.

As tarefas de aprendizado são divididas em duas partes [Katti Faceli et al., 2011]: tarefas preditivas e descritivas.

Tarefas preditivas: Está relacionada com a previsão de um rótulo a partir de uma hipótese. Os modelos preditivos estão relacionados com o paradigma de aprendizado supervisionado. Esse paradigma se baseia na rotulação de um conjunto de dados cujas saídas são conhecidas, a partir daí, a hipótese induzida é capaz de prever valores para novos exemplos.

Tarefas descritivas: Explora um conjunto de dados a fim de descobrir padrões comuns sem a rotulagem de um especialista. Essa característica segue o paradigma de aprendizado não supervisionado, o qual segue o princípio da descoberta de padrões através do agrupamento de dados, encontrando regras de associação que relacionam grupos de atributos.

Esta pesquisa utiliza aprendizado supervisionado para descobrir a atividade do usuário, ofertado um conjunto de característica, os dados são rotulados com as categorias das atividades. O modelo foi gerado utilizando a técnicas de AM árvore de decisão, que será explicada com mais detalhe na próxima seção.

2.3.2.2. Árvore de Decisão

A árvore de decisão é uma das metodologias mais utilizada em mineração de dados. Esse método utiliza uma estrutura de gráficos de fluxo para segregar um conjunto de dados dentro de várias classes pré-definidas, provendo assim, a descrição, categorização e generalização do conjunto de dados [S. Huang et al., 2008].

A árvore de decisão consiste em três tipos de nós: nó raiz, nós internos e nós folhas. O nó raiz e os nós internos representam as decisões de corte que a sentença vai percorrer, enquanto que o nó folha representa o resultado da classificação e cada nó é ligado por ramos.

O modelo lógico da árvore de decisão necessita de uma variável alvo e de variáveis preditoras. Como a variável alvo é o resultado da busca, seus valores estão dispostos nas folhas e as variáveis preditoras estão no nó raiz ou nos nós internos.

O processo de geração da árvore pode ser feita por diversos algoritmos, como: o ID3 [G J.R. Quinlan, 1983], classificação e regressão de árvores [L. Breiman et al., 1984], C4.5 [J.R. Quinlan, 1993], J48 [Witten et al., 2005], *BFTree* [Witten et al., 2005], *DecisionStump* [Witten et al., 2005], *NBTree* [Witten et al., 2005], *RandomTree* [Witten et al., 2005] entre outras variações desses algoritmos.

Perera et al. [2013] listam algumas vantagens e desvantagens da árvore de decisão. As vantagens são: Possui uma boa acurácia em árvores pequenas; Bom desempenho em grandes quantidades de dados; Possui modelos alternativos; e também contém fundamento matemático e estatístico. As desvantagens são: A seleção do conjunto de características pode ser um desafio; O treinamento de dados é requerido; Os modelos podem ser complexos em alguns casos; Dificuldade em capturar conhecimentos em bases que contém muitos atributos.

Esta pesquisa utiliza a árvore de decisão como método de reconhecimento de atividade, as folhas da árvore são as atividades e os atributos de decisão são os elementos do comportamento do usuário que levam à execução de determinada atividade.

2.4. RELAÇÃO ENTRE RECONHECIMENTO DE ATIVIDADE E ECONOMIA DE ENERGIA

Como foi observado na seção anterior, pesquisas de reconhecimento de atividades vêm sendo estudadas e aplicadas em diversos domínios, especialmente, o de economia de

energia elétrica. Pesquisas tem sido feitas com a concepção de que as atividades humanas influenciam diretamente no consumo de energia. Nguyen et al. [2013], por exemplo, citam vários trabalhos que abordam a relação das atividades humanas com o uso de aparelhos elétricos, os estudos são feitos principalmente com aparelhos de refrigeração, aquecimento ou ventilação (do inglês, *heating, ventilation and air conditioning* - HVAC) [B. Dong et al 2009], iluminação [K. Padmanabh et al 2009] e/ou aparelhos conectados a tomadas inteligentes [A. Marchiori et al 2010].

Analisando as soluções de economia de energia baseadas nas atividades dos usuários, Nguyen et al. [2013] detectou quatro categorias de pesquisas:

- i)* **Informação de ocupação em tempo real:** ideal para melhorar os sistemas de luminárias com base em localização, por exemplo, ligar uma luz quando o usuário entrar no ambiente.
- ii)* **Preferências de ocupação em tempo real:** somente técnicas de ocupação baseadas em localização não são suficientes, o ideal seria adicionar parâmetros de tempo para evitar aborrecimento do usuário, por exemplo, desligar a televisão somente após 10 minutos da ausência do usuário, para ter certeza de que o usuário não irá mais assistir televisão.
- iii)* **Previsão de padrões de ocupação:** o controle de temperatura pode ser um elemento de previsão da ocupação do ambiente, ideal para o sistema HVAC.
- iv)* **Detalhamento da atividade:** o detalhe da atividade influencia no conforto do usuário e com base nisso, tomar decisões específicas em cima de cada situação. Por exemplo, saber exatamente os aparelhos que estão desperdiçando energia durante uma atividade.

Essas são as quatro categorias identificadas com relação a trabalhos que economizam energia com base nas atividades dos usuários. A solução proposta neste trabalho atende indiretamente todas as categorias, exceto a previsão de padrões de ocupação.

Como pode ser visto, as atividades humanas e os aparelhos elétricos estão fortemente relacionados. Para representar essa relação no meio computacional, geralmente os autores utilizam algoritmos de ranqueamento para definir o nível de importância de cada aparelho em relação a uma determinada atividade.

Este trabalho utiliza um algoritmo de ranqueamento comumente utilizado na área de recuperação de informação (RI) para ranquear textos. Esse algoritmo foi mapeado para trabalhar com as variáveis “atividades” e “aparelhos” no lugar de “documentos” e “termos”. Este trabalho tanto prevê o ranqueamento dos aparelhos em relação às atividades quanto também faz o processo inverso, ou seja, o ranqueamento das atividades em relação a um conjunto de aparelhos. Isso permite descobrir quais atividades estão sendo executadas apenas com informações dos aparelhos envolvidos.

A próxima seção aborda com mais detalhes o processo de ranqueamento atividade/aparelho e cita os principais algoritmos de ranqueamento existentes.

2.4.1. Algoritmos de Ranqueamento

Os algoritmos de ranqueamento surgiram originalmente para trabalhar com documentos. Com isso, existem vários algoritmos de ranqueamento de documentos na literatura, Ricardo e Berthier et al. [2013], por exemplo, citam os principais algoritmos da literatura como: modelo probabilístico, modelo booleano, modelo vetorial e BM25. Não é objetivo desta pesquisa detalhar esses modelos e algoritmos, mas informar que tais algoritmos podem ser adaptados para outras áreas.

Na área de economia de energia e reconhecimento de atividades, os algoritmos de ranqueamento são utilizados para ranquear aparelhos elétricos e atividades humanas. Lee et al. [2010], por exemplo, utilizam uma fórmula de similaridade similar ao modelo vetorial, Weng et al. [2012] propõem uma fórmula de ranqueamento baseada em logaritmos e Lee et al. [2012] utilizam uma fórmula de ranqueamento baseada em probabilidades.

Para que esses algoritmos sejam utilizados para fazer o ranqueamento de aparelhos elétricos é necessário fazer algumas adaptações. Geralmente essas adequações são apenas de variáveis, não alterando a estrutura do modelo. Neste trabalho, por exemplo, os documentos passaram a ser atividades e os termos do documento passaram a ser aparelhos.

O algoritmo escolhido foi o modelo vetorial. O motivo de sua escolha é que este algoritmo oferece uma garantia maior de precisão no ranqueamento, devido os aparelhos não possuírem problemas de redundância e nem possuir palavras desnecessárias, equivalente às *stop words*, no contexto de documentos. *Stop words* são termos que não fazem sentido para o documento, por exemplo, preposição e artigos.

Observando o contexto de energia, basicamente os algoritmos comparam os aparelhos de uma consulta com a coleção de aparelhos contidos em todas as atividades retornando às mais relevantes, relacionadas aos aparelhos consultados.

2.4.2. Modelo Vetorial

Esta seção apresentará o modelo vetorial no contexto de economia de energia, explicando o funcionamento do processo de ranqueamento dos aparelhos e atividades.

De modo geral, o modelo vetorial consiste na formação de vetores de aparelhos com um peso associado. O peso é uma variável de decisão importante que define o grau de similaridade entre o conjunto de aparelho e atividades. O peso pode ser calculado de várias formas, neste trabalho o método adotado foi a frequência dos aparelhos nas atividades. Como resultado, a similaridade define as atividades mais relevantes para um conjunto de aparelhos, isso permite saber, qual atividade está sendo executada, dado um conjunto de aparelhos.

Além da frequência dos aparelhos em todas as atividades, também foi utilizado como parâmetro de decisão a importância de cada aparelho na coleção, essa informação pode ser obtida com o cálculo do IDF (*Inverse document frequency*) cuja fórmula e funcionamento serão mostrados na próxima seção.

Para facilitar o ranqueamento de atividades, o modelo vetorial programa uma técnica de indexação por meio de um arquivo invertido. Essa técnica consiste em uma estrutura que necessita da criação de um vocabulário de todos os aparelhos distintos que ocorrem em cada atividade. Cada aparelho possui uma lista invertida com as informações de todas as atividades que contém o aparelho.

Após a lista invertida construída, o modelo vetorial começa a formar vetores. Cada elemento do vetor é uma coordenada dimensional em uma dimensão 'n'. Assim, as atividades podem ser colocadas em um espaço euclidiano de 'n' dimensões (onde 'n' é o número de aparelhos) e a posição da atividade em cada dimensão é dada pelo seu peso. A Figura 2.2 ilustra um espaço tridimensional em que as coordenadas podem ser expostas. A próxima seção detalha o modelo vetorial no ponto de vista matemático.




Figura 2.2. Representação gráfica vetorial em que os vetores de documento e expressão das consultas são representados.

2.4.2.1. Representação do Modelo Vetorial Adaptado para Atividade

Segundo OLIVEIRA [2007] o modelo vetorial é representado em vetores no espaço R^n , onde n representa o total de aparelhos e a dimensão do espaço. Cada atividade forma um *vetor de aparelhos*. Logo, tem-se um conjunto de atividades $D = (d_1, d_2, d_3 \dots d_j)$ e cada atividade possui um conjunto de aparelhos $d_j = (t_1, t_2, t_3 \dots t_j)$ onde t_j é o aparelho da atividade. Assim $w_{i,j}$ é o peso associado a cada aparelho t_j na atividade d_j , onde $w_{i,j} \geq 0$ e cada atividade d_j será representada por um vetor de pesos $d_j = (w_{1,j}, w_{2,j}, w_{k,j}, w_{k+1,j}, w_{n,j})$ onde k é o número de todos os aparelhos distintos que aparecem na atividade d_j . Os aparelhos $\{t_{k+1}, t_{k+2}, t_{k+3}, \dots, t_n\}$ associados aos pesos $\{w_{k+1}, w_{k+2}, w_{k+3}, \dots, w_n\}$ representam os aparelhos que aparecem em outras atividades. Portanto $\{t_1, t_2, t_3 \dots t_n\}$ são todos os aparelhos do vetor da atividade d_j , sendo a frequência dos termos igual a zero, uma vez que os aparelhos aparecem apenas em outras atividades.

O peso é calculado levando em consideração a quantidade de vezes que o aparelho aparece na atividade e a importância que esse aparelho tem para o conjunto de atividades. A importância do aparelho sobre toda a coleção de atividades é definida pelo *Inverse Document Frequency* (IDF) dado por:

$$IDF_i = \log \frac{N}{n_i} \quad (\text{Equação 1})$$

Onde N é o número total de atividades e n_i é o número total de atividades onde o aparelho t_i aparece. O IDF calcula a importância do aparelho t_i no conjunto de atividades D . É importante salientar que quanto mais o termo aparece na coleção de atividades, o IDF se aproxima de zero e a relevância do aparelho em relação ao conjunto de atividades diminui, ou seja, quanto mais rara a palavra maior seu IDF. A curva logarítmica mostrada na Figura 2.3 mostra que o objetivo do logaritmo é garantir que conforme a frequência de um aparelho aumenta, sua importância em relação às frequências menores diminua, ou seja, quanto menos o aparelho estiver relacionado com as atividades, maior será seu IDF e conseqüentemente o aparelho será importante para coleção de atividade como um todo e estará fortemente relacionado com alguma atividade.




Figura 2.3. Gráfico representando a curva do IDF.

Após o cálculo do IDF o próximo passo é calcular a frequência de cada aparelho. A frequência $f_{i,j}$ é calculada com a seguinte fórmula:

$$f_{i,j} = \frac{M_{i,j}}{\sum_k^n M_{k,j}} \quad (\text{Equação 2})$$

Onde $M_{i,j}$ indica a frequência do aparelho t_i na atividade d_j e $\sum_k^n M_{k,j}$ é a soma total das frequências em que o aparelho aparece em cada atividade. Essa fórmula define o nível de importância de cada aparelho em relação à determinada atividade. Por fim, calcula-se o peso pela seguinte fórmula:

$$w_{i,j} = f_{i,j} * IDF_i \quad (\text{Equação 3})$$

Onde $f_{i,j}$ é a frequência do aparelho t_i na atividade d_j . Após processamento dos dados, as coordenadas dos vetores das atividades e expressões das consultas são representadas em um plano cartesiano.

Dado que as atividades e as expressões das consultas estão representadas no espaço vetorial com t dimensões, é possível calcular a similaridade entre as atividades distintas, bem como o vetor da expressão de busca. A distância entre os vetores indicam o grau de similaridade entre as atividades. O vetor da consulta é comparado com os vetores das atividades e assim é achada a similaridade entre elas. As atividades similares ou próximas são as mais relevantes para o usuário e conseqüentemente são as que são retornadas, quanto maior a similaridade mais relevante é a atividade. Dado um vetor de atividades d_j e o vetor da expressão de busca q , o cálculo da similaridade é dado pela seguinte fórmula [OLIVEIRA et al. 2007].

$$sim(d_j, q) = \frac{\vec{d}_j * \vec{q}}{|\vec{d}_j| * |\vec{q}|} = \frac{\sum_{i=1}^t w_{i,j} * w_{i,q}}{\sqrt{\sum_{i=1}^t w_{i,j}^2} * \sqrt{\sum_{j=1}^t w_{i,q}^2}} = \cos(\Theta)$$

(Equação 4)

Onde $w_{i,j}$ é o peso do i-ésimo elemento do vetor d_j e $w_{i,q}$ é o peso do i-ésimo elemento do vetor q . O cálculo de similaridade é feito sobre todas atividades e a expressão de busca q , onde através disso, é possível determinar quais atividades são mais relevantes para a busca do usuário. [FERNEDA 2003] completa dizendo que *“Os valores de similaridade são usados no ordenamento dos documentos (ou atividades) relevantes. Portanto, no modelo vetorial o resultado de uma busca é um conjunto de documentos (ou atividades) ordenados pelo grau de similaridade entre cada documento (ou atividades) e a expressão de busca”*.

Capítulo 3

Trabalhos Relacionados

Este capítulo aborda os trabalhos relacionados com esta pesquisa, explanando assuntos da área de reconhecimento de atividade e economia de energia utilizando técnicas de aprendizagem de máquina, ontologias ou algoritmos de lógica simples. Comumente, essas duas abordagens são tratadas separadamente, devido serem áreas de pesquisas distintas, entretanto alguns autores relacionam o reconhecimento de atividade com a economia de energia, por esse motivo alguns trabalhos relacionados tratam apenas de reconhecimento de atividade ou economia de energia. Também, serão mostrados trabalhos que usam árvores de decisão para resolver problemas de consumo de energia ou reconhecimento de atividade.

3.1. CONSUMO DE ENERGIA E RECONHECIMENTO DE ATIVIDADES

3.1.1. Context-aware Home Energy Saving based on Energy-Prone Context

M. Weng et al. [2012] propõem um modelo de contexto que prevê a tendência do consumo dos aparelhos associados às atividades dos usuários. Basicamente, o modelo de economia de energia é baseado em três etapas. A primeira etapa é responsável pela análise do contexto em que o aparelho está inserido. A segunda emprega um algoritmo que determina o potencial de consumo de cada aparelho relacionado à determinada atividade. E por fim, a terceira etapa que é a solução, onde há recomendações de economia de energia ao usuário.

O estudo é baseado no *Energy-Prone Context* (EPC). Essa abordagem é empregada em uma casa inteligente com objetivo de ajudar usuários a economizar energia por meio do emprego sistemático de serviços automáticos baseados na relação entre atividades e aparelhos.

Os aparelhos relacionados à determinada atividade, são classificados em duas categorias: aparelhos de consumo explícito e implícito. O consumo explícito representa os aparelhos que estão diretamente relacionados com a atividade e o consumo implícito representa os aparelhos que estão indiretamente relacionados com determinada atividade. É com base nessas duas características que os algoritmos de recomendações atuam, fazendo recomendações com base no contexto em que o usuário está inserido. A Figura 3.1 mostra uma representação do relacionamento entre atividade e aparelhos.

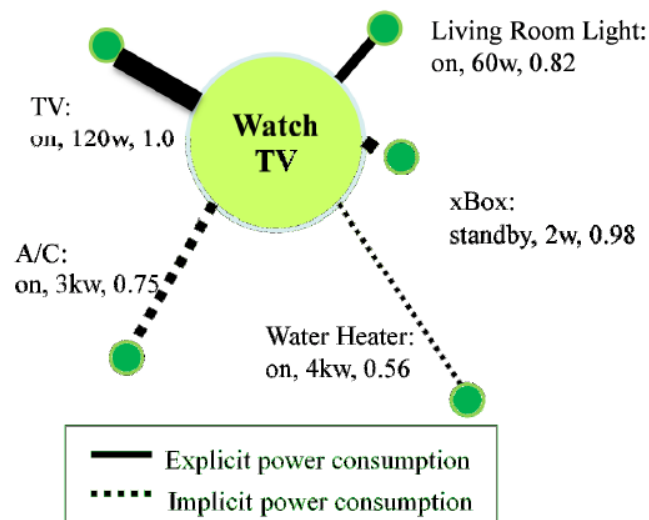


Figura 3.1. Um exemplo do modelo EPC como uma representação gráfica.

Os experimentos foram simulados com base no comportamento real dos usuários, levando em consideração várias atividades do dia-a-dia. Os resultados mostraram que o modelo proposto obteve uma economia de 25% de energia elétrica utilizando uma base simulada.

Nesta dissertação, o vínculo entre os aparelhos elétricos e as atividades dos usuários é feito utilizando um algoritmo de ranqueamento. Tal algoritmo é originado do modelo vetorial comumente utilizado em recuperação de informação para fazer ranqueamento texto. Entretanto, ao invés de ranquear textos o modelo foi adaptado para ranquear aparelhos e atividades. O vínculo entre atividades e aparelhos permite a descoberta de desperdício de energia elétrica de forma mais eficiente.

3.1.2. Integration of IoT Energy Management System with Appliance and Activity Recognition

C. F. Lai et al. [2012] propõem um método capaz de reconhecer aparelhos elétricos, atividades de usuários e definir o nível de relação entre aparelhos e atividades. O reconhecimento de aparelhos elétricos é feito com base no pico de consumo de cada aparelho. Para isso, classificadores são utilizados para descobrir padrões de consumo dos aparelhos para posteriormente, serem reconhecidos com base nos padrões definidos. Os classificadores utilizados para análise de dados foram: KNN, *Naive Bayes* e árvore de decisão.

O reconhecimento de atividades é feita com base no número de aparelhos que estão em operação. A estratégia utilizada é a análise do período de tempo em que um conjunto de aparelhos permanece em execução. Diagramas de blocos são utilizados para representar os períodos de tempo, onde cada bloco representa a possibilidade de ocorrer uma atividade em determinado intervalo, como mostra a Figura 3.2.




Figura 3.2. Exemplo de diagrama de blocos baseado no tempo. Cada bloco representa uma atividade sendo executada em um tempo T enquanto os aparelhos D estão em execução. Este período forma blocos B's menores que são períodos utilizados para identificar uma atividade.

Para medir a relevância das atividades relacionada aos aparelhos, utilizou-se um algoritmo de ranqueamento probabilístico. O ranking retorna cada atividade com seus respectivos aparelhos, ranqueados do mais importante para o menos importante.

Os experimentos analisaram precisão e revocação dos algoritmos de ranqueamento e dos classificadores. Na comparação entre os classificadores, o algoritmo que teve melhor resultado foi o *Naive Bayes*. Não foi realizado nenhum teste para saber a taxa de economia de energia dos aparelhos envolvidos na pesquisa.

3.1.3. Appliance Recognition and Unattended Appliance Detection for Energy Conservation

S. Lee et al. [2010] propõem um framework para prover serviços de economia de energia baseado no reconhecimento de aparelhos elétricos e atividades dos usuários. O *framework*

proposto consiste em quatro modelos de processos: *i)* modelo de reconhecimento de aparelho; *ii)* modelo de relacionamento entre atividade e aparelho; *iii)* modelo para detectar aparelhos ligados desnecessariamente com base nas atividades dos usuários; *iv)* modelo para fornecer informações de consumo ao usuário.

O modelo de reconhecimento de aparelhos obtém as características e o status da operação de cada aparelho antes de iniciar o processo de reconhecimento. Em seguida, o processo de reconhecimento inicia sob uma base de dados treinada utilizando algoritmos de aprendizagem de máquina.

O modelo de relacionamento entre atividades e aparelhos aplicam algoritmos de ranqueamento para descobrir a associação entre uma atividade e um conjunto de aparelhos. A Figura 3.3 mostra graficamente o nível de relação em que cada aparelho tem com uma determinada atividade.

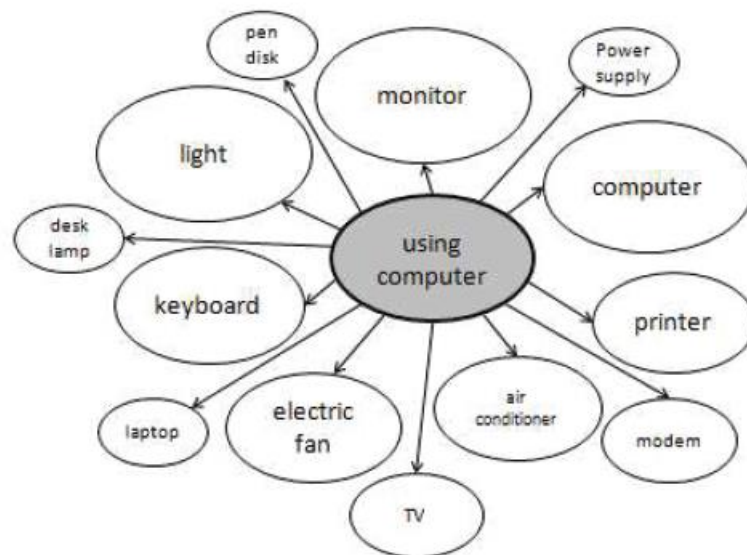


Figura 3.3. Exemplo de aparelhos vinculados à atividade 'Usando computador'. Os tamanhos das bolinhas indicam o nível de relação dos aparelhos com a atividade.

O modelo responsável por detectar aparelhos ligados desnecessariamente é baseado no nível de relação atividade/aparelho. Por exemplo, quando um aparelho não tem relação com nenhuma atividade em execução e está em operação, considera-se que este aparelho está desperdiçando energia elétrica. Por fim, o *framework* fornece um conjunto de serviços que permite ao usuário monitorar o consumo de energia de sua residência.

Os experimentos foram divididos em duas partes. A primeira analisa o modelo de reconhecimento de aparelho escolhendo o algoritmo de aprendizagem de máquina que

melhor se adéqua a este problema. A segunda avalia a precisão e revocação da relação entre atividade e aparelho.

3.2. ECONOMIA DE ENERGIA

3.2.1. A Location-Aware Lifestyle Improvement System to Save Energy in Smart Home

Z. Cheng and Y. Ozawa [2012] propõem uma solução para economizar energia elétrica em uma casa inteligente com base na localização dos usuários. Para isso, foram criados algoritmos de recomendação que se baseiam na classificação de aparelhos domésticos e na necessidade da presença ou não do usuário no período de execução do aparelho.

A solução proposta concentra-se em resolver quatro problemas: *i)* como detectar e gravar a posição do usuário na casa; *ii)* como medir o consumo de energia dos aparelhos; *iii)* como reconhecer o desperdício de eletricidade e, *iv)* como melhorar o hábito do estilo de vida dos usuários.

Para isso, técnicas de localização *indoor* foram utilizadas para detectar a posição dos usuários e sensores de corrente elétrica foram utilizados para medir o consumo dos aparelhos. Para identificar o desperdício de energia foram definidas duas métricas: padrão de consumo dos aparelhos baseados no tempo e categorização dos aparelhos domésticos. O padrão de consumo baseado no tempo leva em consideração a hora do dia, observando principalmente, o horário de pico para tomada de decisões. As classificações de aparelhos domésticos se baseiam na necessidade da presença ou não do usuário no período em que o aparelho fica ligado, como mostrado na Tabela 3.1.

Tabela 3.1. Tipo de aparelhos. Classificação de aparelhos que necessitam ou não de ficar ligados na presença do usuário e também se é possível prever o tempo em que os aparelhos ficaram ligados.

	Presença do usuário	Prevê tempo	Exemplo
1	Necessário	Impossível	Televisão, luz
2	Não necessário	Impossível	Refrigerador
3	Necessário	Possível	Aspirador
4	Não necessário	Possível	Máquina de lavar

Com base na classificação dos aparelhos, algoritmos de recomendação são propostos para tratar cada categoria de aparelho. Por exemplo, caso um aparelho do tipo 1 esteja ligado sem a presença do usuário, o algoritmo recomenda que este aparelho seja desligado.

Essas recomendações influenciam na mudança de hábito do usuário e conseqüentemente o seu estilo de vida.

Para validar a solução proposta, testes foram feitos em um ambiente real e os resultados foram baseados na comparação do consumo de energia “com” e “sem” a aplicação dos algoritmos de recomendação. O objetivo é determinar o quanto de energia foi economizado e o tempo de uso dos aparelhos domésticos.

As categorias dos aparelhos são baseadas no tempo e na presença do usuário. Ambas as características combinadas, formam quatro tipos de tratamentos diferentes para os algoritmos de recomendação. O método proposto nesta dissertação propõe quatro categorias baseadas no tempo e quando combinadas com a presença do usuário formam 6 tipos de tratamentos diferentes para os algoritmos de recomendação, essas categorias são explicadas com mais detalhes no Capítulo 4.

3.2.2. A semantic Representation of Energy-Related Information in Future Smart Homes

M. J. Kofler et al. [2012] propõem um modelo semântico de energia que prevê a demanda e o suprimento, aplicado a ambientes domésticos de casas inteligentes. Esse modelo utiliza recursos de um modelo existente chamado DogOnt [D. Bonino and F. Corno, 2008]. O DogOnt é um modelo ontológico que representa objetos do mundo real e é capaz de suportar mecanismos de interoperabilidade e inteligência dentro de um ambiente automatizado. O objetivo é integrar o novo modelo de energia proposto ao modelo DogOnt, uma vez que o DogOnt não prevê consumo de energia elétrica.

Espera-se que o sistema proposto tenha ciência dos diferentes parâmetros e facilidades energéticas, assim como, provedores que tomam decisões de acordo com as preferências do usuário. O sistema deve computar e executar automaticamente estratégias de uso, iterações e controle do contexto do ambiente. Além disso, o sistema deve estar ciente da informação de ocupação, assim como, noções de quando determinado aparelho é utilizado.

O sistema inteligente usa o modelo ontológico com vários módulos contendo diferentes tipos de informações importantes para eficiência de energia elétrica. Os módulos representam diferentes domínios do sistema, todos reúnem um modelo genérico chamado *Smart Home Ontology* (SHO). O modelo proposto pode ser utilizado nos seguintes estudos

de caso: determinar provedores de energia verde, desconectar equipamentos que estão em uso desnecessariamente e selecionar provedores disponíveis que ofereça serviços mais barato.

A principal contribuição desse trabalho foi criar um modelo de energia e integrar esse modelo ao DogOnt. Essa contribuição torna o DogOnt mais completo e com possibilidade de prever o consumo de energia. Além disso, a integração de diferentes modelos SHO pode contribuir para eficiência no consumo de energia em ambiente domóticos.

3.2.3. OWL Ontologies and SWRL Rules Applied to Energy Management

A. Rossello-Busquet et al. [2011] propõem um *gateway* residencial para sistemas de gerenciamento de energia. Esse *gateway* foi desenvolvido usando o *framework Open Service Gateway Initiative (OSGi)* [M. J. Kofler et al., 2012] composto por uma base de conhecimento baseado no modelo ontológico DogOnt [D. Bonino and F. Corno, 2008]. O usuário pode definir regras para aplicar estratégias de gerenciamento de energia para minimizar o consumo de aparelhos domésticos.

Para implementar as estratégias de gerenciamento de energia no *gateway*, uma *Rule Engine* foi usada, permitindo ao usuário criar, modificar e deletar regras através de uma interface gráfica. As regras são avaliadas sempre que a base de conhecimento for mudada. Por exemplo, quando o *gateway* recebe a notificação do sensor sobre informação de status, um processo seleciona a regra necessária. A Figura 3.4 mostra um exemplo de regras.

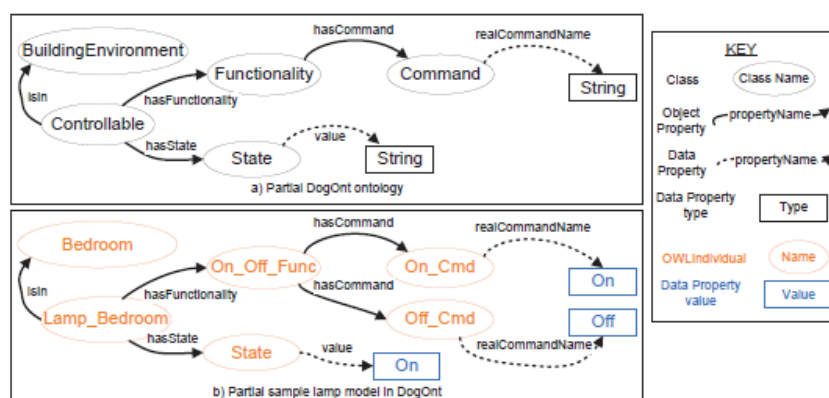


Figura 3.4. Regras de um modelo ontológico para energia. Essa Figura mostra um exemplo de atuação de um dispositivo controlável no modelo da arquitetura DogOnt.

O objetivo desse artigo foi criar regras de inferência baseadas na linguagem OWL sobre o próprio modelo ontológico para ligar ou desligar dispositivos dependendo do contexto. Essa criação de regras sobre o próprio modelo é umas das abordagens de

inferência de contexto, mas somente isso não é suficiente para aplicar uma inteligência concreta, uma sugestão é aplicar técnicas de aprendizagem de máquina para criar essas regras de forma mais eficiente.

3.2.4. A Decision Tree Method for Building Energy Demand Modeling

Z. Yu et al. [2010] propõem um modelo preditivo baseado em árvore de decisão com o objetivo de economizar energia em prédios residenciais. O método é utilizado para estimar o consumo de energia com base no nível de intensidade do uso dos dispositivos elétricos. O modelo prevê se a intensidade do uso de energia (EUI) é alta (HIGH) ou baixa (LOW). A EUI é classificada com base na condição do clima, características do prédio, características da residência e características dos aparelhos. A Figura 3.5 mostra a árvore de decisão gerada.

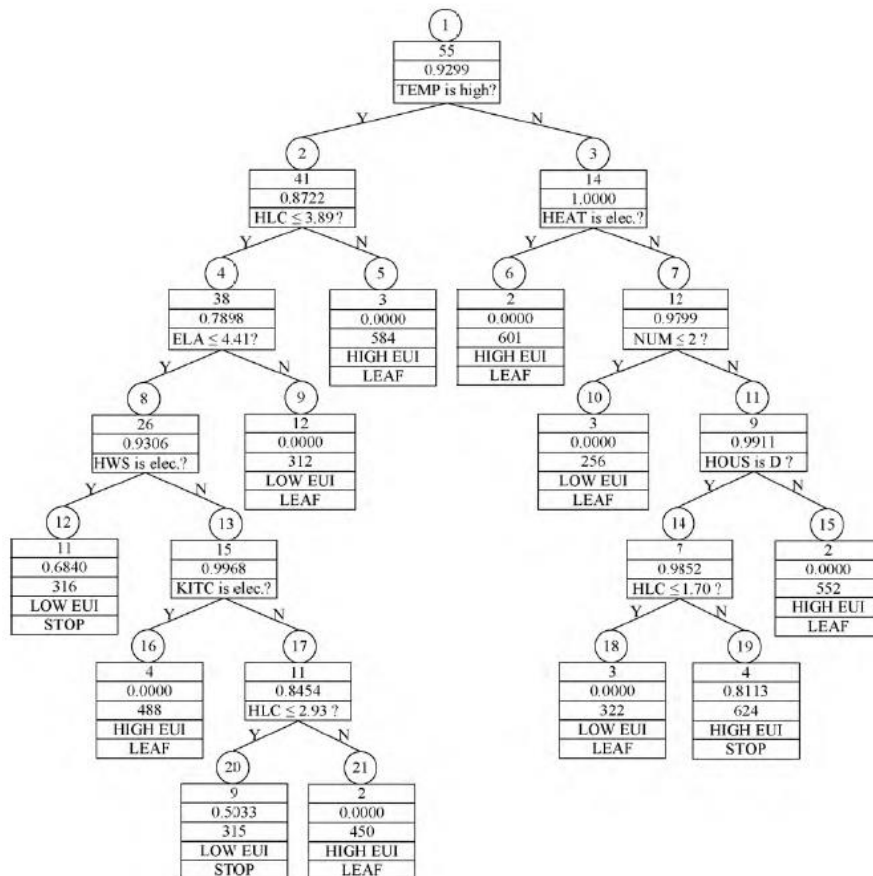


Figura 3.5. Árvore de decisão que prevê o nível de EUI dos prédios. Os dados contidos na árvore são o número do nó, dados gravados nesse nó, entropia, teste de corte e atributos de classificação (folha).

Os dados dessa pesquisa foram analisados de uma base chamada “Energy consumption for residential buildings in Japan”, é uma base que contém informações de 80 prédios residenciais localizados em seis diferentes distritos do Japão. O método teve uma

acurácia de 93% no treinamento dos dados e 92% nos testes, isso é um resultado bastante aceitável, comparado a outros métodos de aprendizagem.

A vantagem desse método é o aumento da performance do consumo de energia e a redução de custos. Além disso, o método obteve um bom resultado de previsão e classificação para esse problema em particular, além da interpretação ser mais fácil que outros métodos de regressão ou redes neurais artificiais.

3.3. RECONHECIMENTO DE ATIVIDADES

3.3.1. Online Activity Recognition Using Evolving Classifiers

F. J. Ordóñez et al. [2013] focam no reconhecimento de atividades diárias básicas (do inglês, *Activity Daily Living* - ADL) utilizando a técnica de classificação lógica *fuzzy*. Essa técnica cria padrões de regras baseadas na variação do tempo em que cada atividade é executada.

O processo de classificação é dividido em duas classes de regras. A primeira classe prevê apenas uma única atividade no resultado de uma condição lógica e a segunda classe prevê um conjunto de atividades representadas por um vetor. As regras utilizam lógica simples, como a estrutura de decisão IF-THEN-ELSE. As regras geradas são integradas ao modelo de classificação automaticamente.

O classificador é comparado com os seguintes algoritmos de aprendizagem de máquina: *Hidden Markov Model (HMM)*, *Naive Bayes* e *k-Nearest Neighbor (kNN)*. As métricas utilizadas para avaliação da solução foi precisão e revocação e os resultados mostraram que o classificador proposto funciona tão bem quanto os métodos probabilísticos de aprendizagem de máquina, obtendo vantagens com o treinamento ao longo dos dias.

A principal vantagem desse trabalho é que o classificador é dinâmico e capaz de se adaptar a constantes mudanças no comportamento humano, uma vez que métodos tradicionais criam modelos estáticos, limitando o reconhecimento de padrões pré-definidos.

3.3.2. Recognizing Independent and Joint Activities Among Multiple Residents in Smart Environments

G. Singla et al. [2010] propõem uma solução para reconhecer atividades dos usuários em um ambiente inteligente em tempo real. Para isso, foi utilizado o algoritmo de aprendizagem de

máquina cadeias escondidas de Markov (do inglês, *Hidden Markov Model* - HMM). A natureza probabilística do algoritmo facilita a identificação de variações na maneira em que as atividades são executadas.

As atividades são reconhecidas com base nas análises das sequências dos eventos disparados nos sensores, cada evento representa um estado finito que depende de um histórico de estados. O objetivo é encontrar a sequência mais provável de estados escondidos ou atividades que podem ser geradas pela sequência de eventos, como mostrado na Figura 3.6.

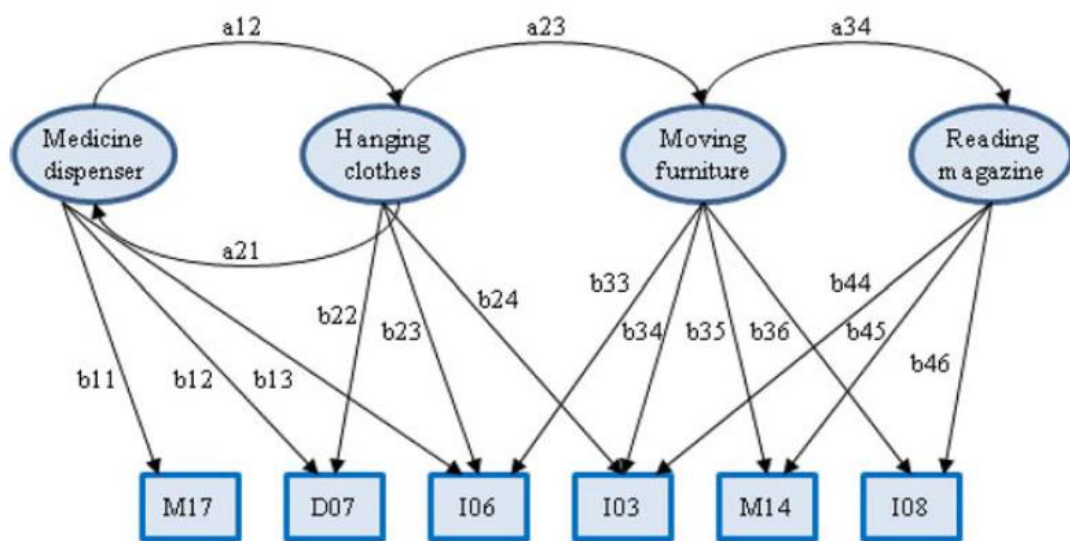


Figura 3.6. Exemplo de atividades representadas na cadeia escondida de Markov. Os círculos apresentam estados escondidos ou atividades e os retângulos representam os estados visíveis. As arestas representam as transições com as probabilidades.

O algoritmo obteve uma acurácia de 60,60%, analisando 15 atividades realizadas em um apartamento. Esse resultado, demonstra que o HMM nem sempre é viável, devido à incapacidade de separar as sequências dos eventos dos sensores dentro de subsequências não sobrepostas que correspondem à cada atividade individual. Como pode ser observado, esse modelo não é muito confiável para o reconhecimento das atividades, pois a taxa de erro de 39,40% é muito alta.

3.3.3. Development of Context Aware System based on Bayesian Network Driven Context Reasoning Method and Ontology Context Modeling

K. Ko and K. Sim [2008] propõem uma nova abordagem de reconhecimento de atividades utilizando modelos ontológicos. Essa abordagem cria um modelo baseado em subconjunto concreto de informações que são capturadas por meio de sensores e apresentadas de forma

estruturada aos usuários. Esse modelo representa um conhecimento probabilístico que será usado na inferência dos dados. O método escolhido para inferência foi às redes bayesianas, devido ser um método que representa questões de incerteza por meio de probabilidades.

As redes bayesianas foram utilizadas para reconhecer as atividades dos usuários. A rede contém informações que respondem às seguintes perguntas: “quem?”, “onde?”, “como?” e “quando?” a atividade foi realizada. Essas informações são utilizadas para fazer inferência sobre os dados e tomar alguma decisão. A Figura 3.7 mostra um exemplo de uma estrutura de redes bayesianas para o reconhecimento da atividade.




Figura 3.7. Estrutura das redes bayesianas para inferência de atividade.

Os experimentos foram realizados por meio de simulação de um ambiente fictício. Os testes analisam as atividades mais frequentes e a porcentagem dos atributos dos possíveis caminhos da rede bayesiana até chegar à determinada atividade. Não há nenhuma comparação com outros algoritmos de aprendizagem, mas os trabalhos futuros sugerem aplicação deste problema com as redes neurais artificiais para reforçar a precisão dos resultados.

3.4. DISCUSSÕES

Os trabalhos relacionados estão divididos em três grupos de pesquisa: O primeiro grupo trata de trabalhos que economizam energia com base nas atividades dos usuários. O segundo grupo trata de trabalhos com soluções somente de economia de energia. Por fim, o terceiro grupo trata trabalhos com soluções para reconhecimento de atividades dos usuários.

Economia de energia e reconhecimento de atividade são duas áreas de pesquisas distintas. Como foram observados, alguns trabalhos [M. Weng et al., 2012], [C. F. Lai et al., 2012] e [S. Lee et al., 2010] juntaram as áreas no intuito de criar soluções mais eficientes para economizar energia elétrica com base nas atividades dos usuários. O estudo separado das duas áreas permitiu o conhecimento da variabilidade de soluções. As pesquisas de reconhecimento de atividade, por exemplo, focam mais na utilização de técnicas de aprendizagem de máquina na solução de problemas. As pesquisas de economia de energia apresentam soluções mais variadas, por exemplo, o uso de lógica simples, ontologias e classificadores. A Tabela 3.2 mostra uma comparação dos trabalhos apresentados com base nas características em comum apresentadas.

Tabela 3.2. Comparação dos trabalhos relacionados.

		Weng et al. [2012]	Lai et al. [2012]	Lee et al. [2010]	Cheng and Ozawa [2012]	Kofler et al. [2012]	Rossello-Busquet et al. [2011]	Yu et al. [2010]	Ordóñez et al. [2013]	Singla et al. [2010]	Ko and Sim [2008]
1	Reconhecimento de Atividade		X	X	X				X	X	X
2	Reconhecimento de aparelho			X	X						
3	Economia de energia	X	X	X	X	X	X	X			
4	Teste em ambiente real	X			X			X	X	X	
5	Algoritmo de aprendizagem							X	X	X	X
6	Algoritmo de ranqueamento		X	X	X						
7	Regras simples	X	X								
8	Modelos matemáticos			X	X						
9	Ciência de contexto	X	X								X
10	Ontologia					X	X				X

A Tabela 3.2 resume as principais características encontradas em trabalhos de economia de energia e reconhecimento de atividade. Basicamente a tabela mostra a ausência e presença dessas características nos trabalhos analisados.

Um fato curioso, é que nesta área de pesquisa, os trabalhos não costumam ser comparados entre si. Um dos motivos para este fato é que as bases de dados utilizadas nos testes não são divulgadas, obrigando os pesquisadores a utilizarem bases de dados própria que na maioria das vezes são simuladas. Com isso, percebe-se que cada solução se limita a características específicas de cada base de dados, dificultando a reprodução dos resultados em uma base com características diferentes.

Outro motivo que dificulta a comparação dos resultados, é a variabilidade do comportamento dos usuários, principalmente quando os testes são realizados em ambientes

reais. Por exemplo, uma solução aplicada em uma determinada residência, não terá o mesmo resultado em outra residência, devido os usuários possuírem comportamentos diferentes. Weng et al. [2012] economizou 25% de energia no seu cenário, mas se sua solução for aplicada em outro cenário, a taxa pode variar tanto pra mais quanto pra menos.

Diferentes dos trabalhos apresentados acima, o método proposto contém a maioria dos itens citados na Tabela 3.2, exceto os itens 2, 8, 9 e 10. O método proposto se destaca pela sua completude, abrangendo desde a coleta de dados no ambiente até as recomendações ao usuário.

Além deste diferencial, o método também possui inovações em todas as suas fases de processos. Foi combinado o classificador baseado em árvore de decisão juntamente com a distância euclidiana na fase de reconhecimento de atividade. Foi utilizado o modelo de espaço vetorial adaptado para fazer o ranqueamento atividade/aparelho e vice-versa. Por fim, foi acrescentado uma nova classe de aparelho para auxiliar os algoritmos de recomendações na tomada decisão.

Capítulo 4

Método Proposto

Este capítulo aborda detalhes do método AAEC (*Activity-Appliance-Energy Consumption*) como solução de economia de energia em ambientes inteligentes. Primeiramente será mostrada uma visão geral do método proposto por meio de uma arquitetura contendo seus componentes principais. As seções seguintes detalham cada componente arquitetural, explicando quais métodos e técnicas são utilizadas na solução do problema de cada componente. Para facilitar o entendimento da solução, o funcionamento do método foi modelado na linguagem visual BPMN, descrita no Capítulo 2.

4.1. VISÃO GERAL

Esta seção apresenta o método AAEC (*Activity-Appliance-Energy Consumption*) proposto para reconhecer as atividades dos usuários, relacionar atividade/aparelhos e recomendar ações ao usuário para evitar desperdícios de energia elétrica. A Figura 4.1 mostra a visão geral do método AAEC.

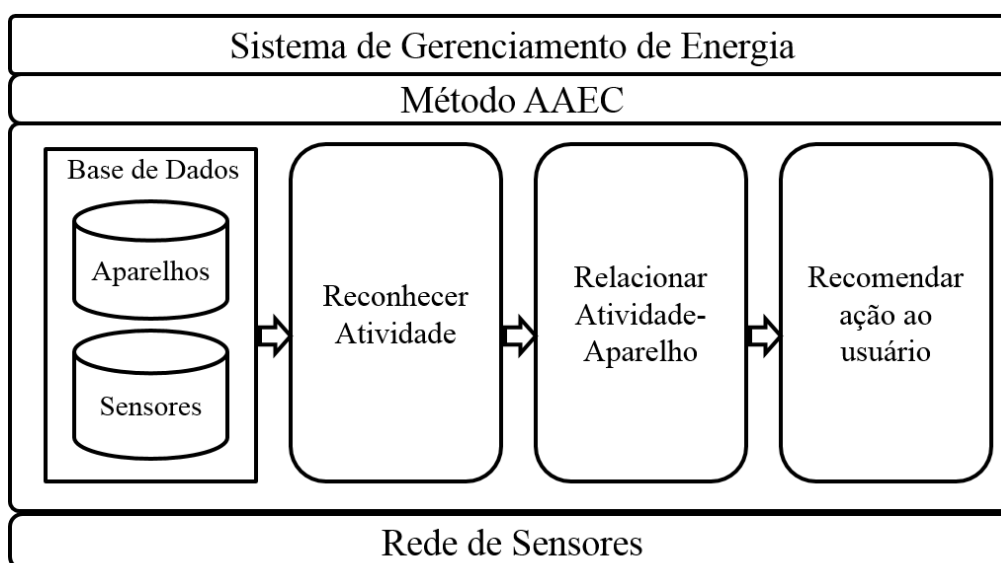


Figura 4.1. Visão geral do método AAEC.

O processo de reconhecimento de atividade do usuário é realizado por meio do processamento das informações extraídas dos sensores e aparelhos. Esse processo utiliza um algoritmo de árvore de decisão para determinar a categoria de uma atividade e um algoritmo de distância euclidiana para reconhecer a atividade associada a uma categoria, com base na análise do tempo de execução dos sensores.

A relação entre atividade e aparelhos define o quanto determinado aparelho é importante para uma atividade. Um rank que estabelece o nível de importância que um aparelho possui com relação a uma atividade é definido por um modelo de espaço vetorial de similaridade, ou simplesmente modelo vetorial. Algoritmos de recomendação utilizam esta relação para identificar os aparelhos que estão desperdiçando energia elétrica durante a execução de uma atividade.

Uma vez conhecidos os aparelhos associados a uma determinada atividade, um algoritmo é empregado para recomendar ações para o usuário com base na análise dos tipos de aparelhos, necessidade da presença do usuário durante a execução do aparelho, horários e especificações de consumo.

4.2. MODELAGEM DE PROCESSOS DO MÉTODO AAEC






Esta seção apresenta uma abstração de como funciona o método AAEC, fornecendo o entendimento de como as atividades são realizadas para alcançar o objetivo proposto. A modelagem do método AAEC é realizada usando a notação de modelagem de processos de negócio ou BPMN (Business Process Modeling Notation) [OMG, 2011].

A linguagem BPMN pode representar perfeitamente características do mundo real, pois é possível representar objetos heterogêneos interconectados capturando status de informações físicas em um ambiente [S. Meyer and K. Sperner, 2011]. Meyer e Sperner destacam ainda que a linguagem BPMN é mais completa para a modelagem de processamentos em tempo real quando comparados com as linguagens como UML (*Unified Modeling Language*) e eEPC (*Extended Event-driven Process Chain*).

Os processos de negócios da linguagem BPMN são formados por elementos que proveem informações adicionais a cada processo. Tais elementos são responsáveis por definir o comportamento dos processos. Os elementos são categorizados em objetos de fluxo, objetos de conexão, dados, faixas e artefatos. A Tabela 4.1 mostra os principais

elementos gráficos básicos responsáveis pela criação dos diagramas dos processos de negócios.

Tabela 4.1. Principais elementos básicos de modelagem da linguagem BPMN 2.0.

Elemento	Descrição	Notação
Evento	Um evento define o comportamento que ocorre durante a execução de um processo	
Atividade	Atividade é um termo genérico que define a tarefa de um processo ou sub-processo.	
Decisão	Elemento utilizado para decidir o fluxo dos processos.	
Fluxo de sequência	O fluxo de sequência mostra a ordem em que as atividades são executadas.	
Fluxo de mensagem	O fluxo de mensagem mostra o fluxo de mensagem entre dois participantes.	

A Figura 4.2 mostra os processos de negócios do método AAEC utilizando a linguagem BPMN 2.0. A modelagem contém processos e sub processos que possuem eventos iniciais e finais. A modelagem é dividida em três blocos de processos agrupados por funcionalidades. Os primeiros blocos tratam das coletas de dados dos sensores e dos aparelhos espalhados em uma residência. O bloco HEMS contém três grupos de processos separados por faixas. Os processos reconhecer atividade e relacionar atividade/aparelho possuem sub processos (blocos cinzas) que são executados conforme necessidade. As próximas seções irão abordar com mais detalhe cada processo e sub processo do método AAEC.

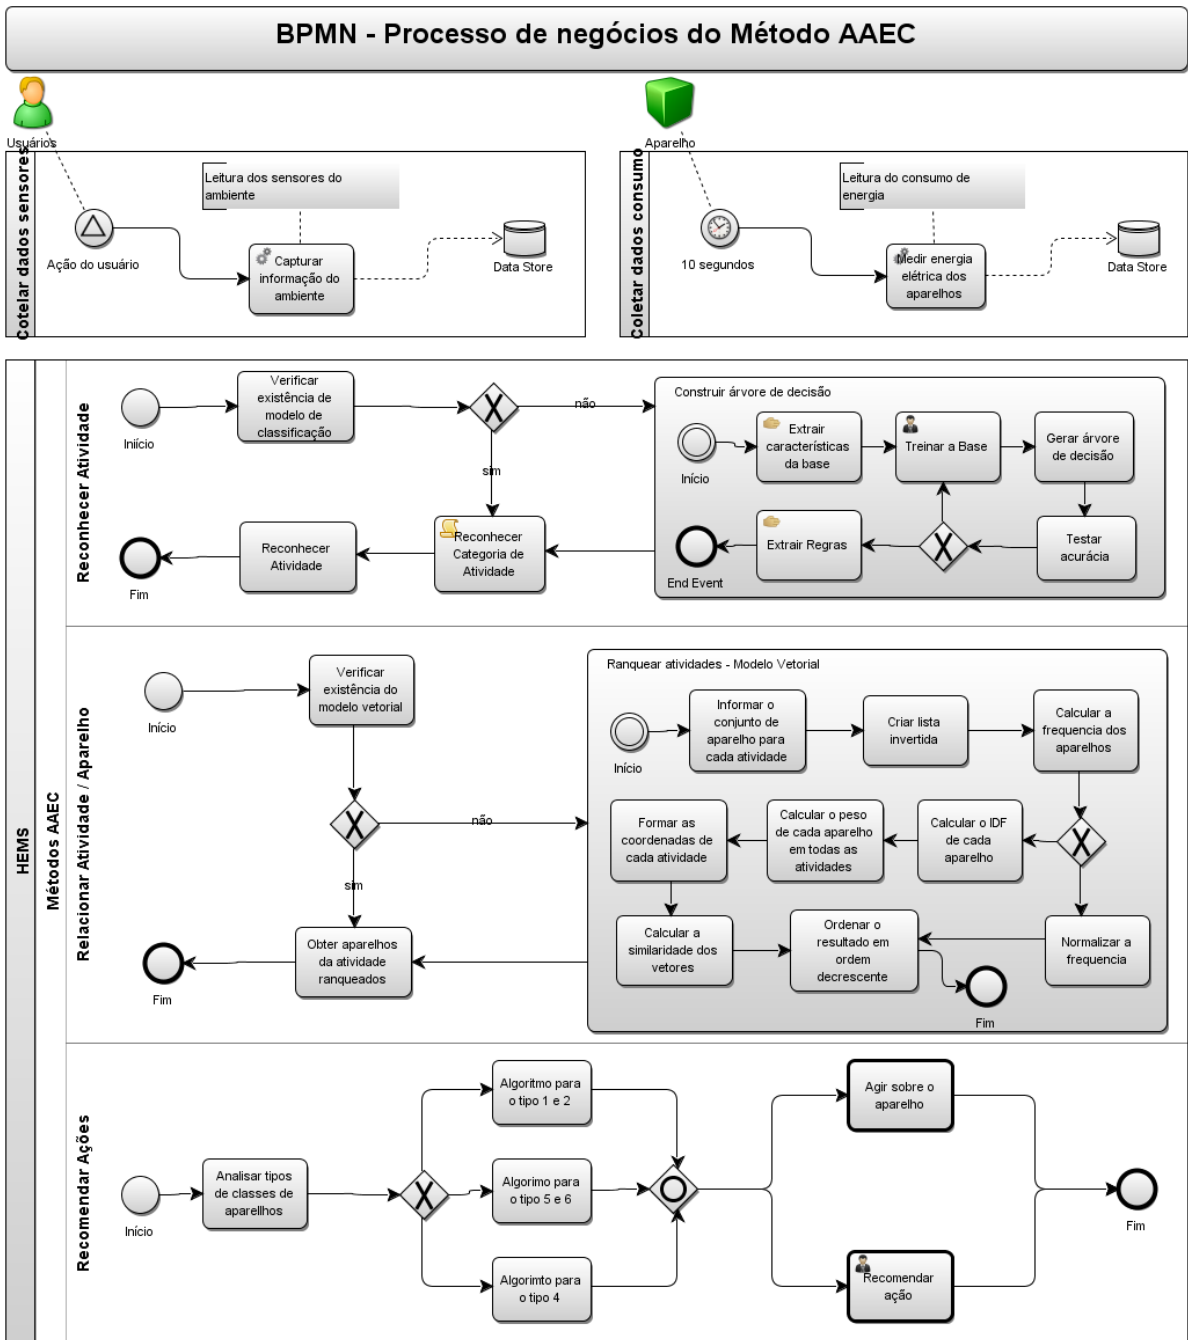


Figura 4.2. Modelo do processo de negócios da proposta.

4.2.1. Coleta de Dados dos Sensores

O diagrama mostrado na Figura 4.3 apresenta o processo de coleta de informações dos sensores instalados no ambiente a ser monitorado. O processo inicia observando a interação do usuário com o ambiente a partir das informações coletadas pelos diferentes sensores, que são enviadas para uma base de dados.

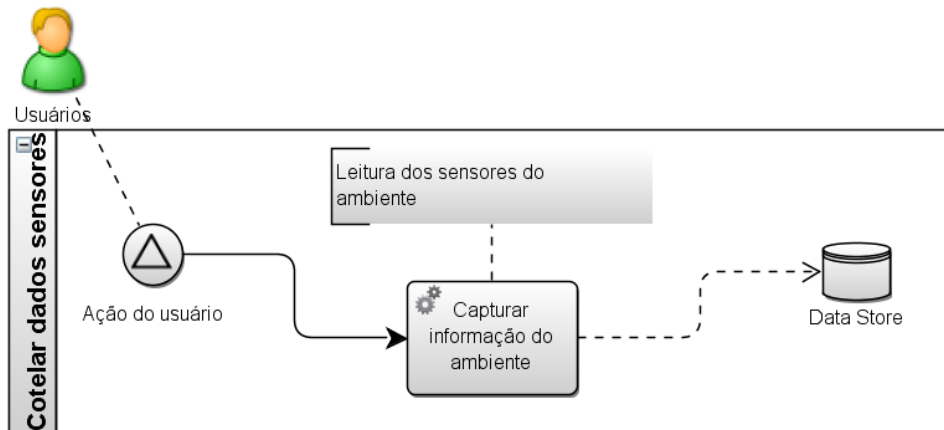


Figura 4.3. Processo de coleta de dados das redes de sensores.

4.2.2. Coleta do Consumo de Energia

O diagrama mostrado na Figura 4.4 apresenta o processo de coleta de informações de consumo de energia dos aparelhos eletrodomésticos instalados no ambiente a ser monitorado. Neste processo, um evento é disparado a cada 10 segundos para medir o consumo de energia elétrica dos aparelhos. Essa medição é realizada através de sensores de corrente elétrica. As informações de consumo são então enviadas para uma base de dados.

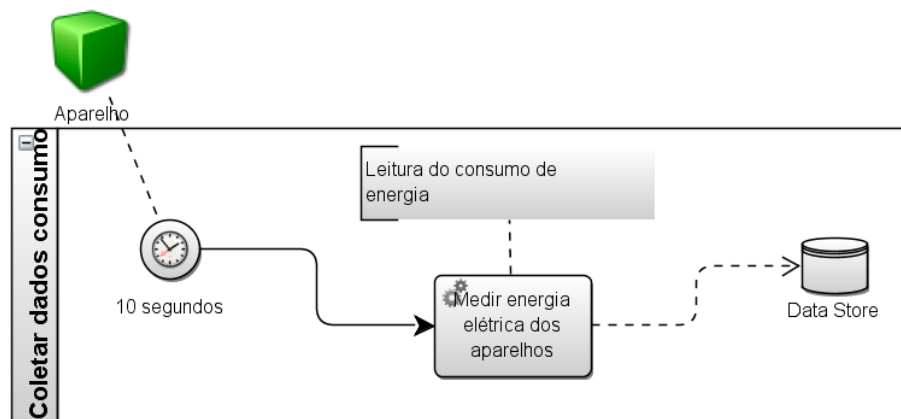


Figura 4.4. Processo de medição do consumo dos aparelhos.

4.2.3. Reconhecimento de Atividade

O diagrama da Figura 4.5 descreve o processo de reconhecimento de atividade do usuário. O processo inicia com uma verificação da existência ou não de um modelo de classificação. Caso o modelo não tenha sido criado, o sub processo para criação do modelo baseado em árvore de decisão é iniciado. Caso contrário, o processo segue com o reconhecimento de atividade.

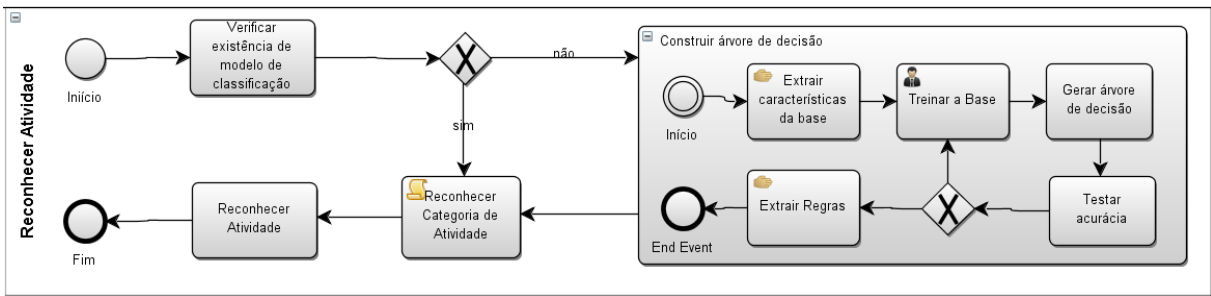


Figura 4.5. Processo de negócio do reconhecimento de atividade.

O subprocesso que cria o modelo de classificação organiza os dados de forma estruturada de acordo com as características definidas previamente (local onde os sensores estão instalados). Em seguida, inicia-se o processo de treinamento para criação das regras da árvore de decisão. Enquanto a acurácia do modelo gerado não for satisfatória, o processo de treinamento é executado novamente. A Figura 4.6 mostra um exemplo representativo de uma árvore da decisão com as categorias de atividades como atributo alvo.

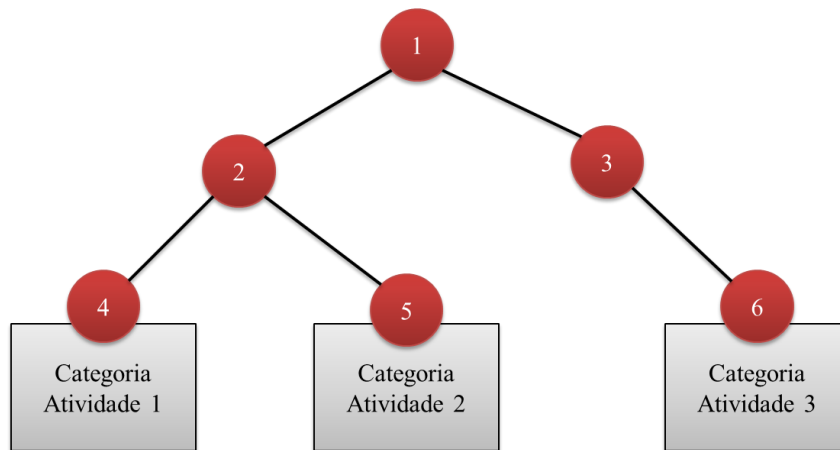


Figura 4.6. Exemplo representativo da árvore de decisão.

O processo de reconhecimento de atividade compreende em reconhecer a categoria e a atividade pertencente a uma categoria. O reconhecimento da categoria é baseado em regras geradas pelo algoritmo de árvore de decisão que considera o objeto (aparelho, móveis, etc.) e o local onde os sensores estão instalados. Por exemplo, as atividades poderiam ser categorizadas como cozinhar, educação, lazer, movimento no ambiente e necessidades pessoais.

Após o reconhecimento da categoria, o próximo passo é reconhecer a atividade que deverá estar associada a uma categoria. O reconhecimento da atividade é baseada na análise do tempo de execução dos sensores. Cada categoria possui um conjunto de

atividades que são executadas em um determinado período de tempo. Por exemplo, uma pessoa demora em média 40 minutos para fazer o almoço e cerca de 10 minutos para preparar um lanche. Logo, o tempo de execução do sensor pode ser comparado com a média de tempo contida em um histórico de atividades como mostrado na Tabela 4.2.

Tabela 4.2. Exemplo das atividades da categoria ‘Cozinhar’, executada na cozinha. O tempo de execução do sensor está mais próximo de ‘Preparar bebida’.

Categoria	Localização	Atividade	Média de Execução da Atividade (segundos)	Tempo do Sensor (segundos)
Cozinhar	Cozinha	Preparar bebida	544	603
Cozinhar	Cozinha	Preparar lanche	470	603
Cozinhar	Cozinha	Preparar café	898	603
Cozinhar	Cozinha	Preparar jantar	1220	603
Cozinhar	Cozinha	Preparar almoço	2275	603

Para determinar quão próximo o tempo de execução de um sensor está da média de um tempo registrado de uma atividade é utilizada a medida de distância euclidiana [P. E. Danielsson, 1980] definida como:

$$\sqrt{(p_x - q_x)^2} = |p_x - q_x| \quad (\text{Equação 5})$$

Onde p_x é a média de execução de uma determinada atividade e q_x é o tempo em que o sensor permaneceu ativo. A medida de distância Euclidiana é comumente empregada para tomar a decisão de pertinência de um ponto a uma classe, nesse caso de uma atividade a uma categoria. O algoritmo 1 apresenta um pseudocódigo para o cálculo da distância Euclidiana.

Algoritmo 1. Algoritmo que trata da distância euclidiana.

-
1. **para cada** *atividades da categoria reconhecida* **faca**
 2. media = obtem a media de execucao da atividade
 3. distancia = |tempo de execucao do sensor – media|
 4. **se** *distancia < distancia_minima* **entao**
 5. distancia_minima = distancia
-

Em resumo, o código percorre todas as atividades da categoria reconhecida e obtém a média de execução de cada atividade (linhas 1 e 2). Em seguida, a distância entre dois pontos é calculada através do tempo de duração do sensor subtraído da média de execução de cada atividade (linha 3). Por fim, se a distância calculada for menor que a distância mínima então essa distância passa a ser a menor (linhas 4 e 5).

Após o reconhecimento da atividade por meio das regras da árvore de decisão e da distância euclidiana, o próximo passo é relacionar atividades/aparelhos.

4.2.4. Relação entre Atividade e Aparelho

As atividades desenvolvidas pelos usuários tem impacto considerável na quantidade de energia consumida em ambientes residenciais. Portanto, estabelecer a relação entre as atividades e aparelhos é importante para ajustar o uso dos aparelhos de acordo com as necessidades reais dos usuários. Por exemplo, “quando alguém assiste televisão na sala, quais aparelhos estão associados a esta atividade?”. A resposta a essa pergunta pode ajudar na identificação de dispositivos que podem estar ligados sem necessidade como as luzes do quarto e do banheiro.

A relação atividade/aparelho é uma relação biunívoca determinada da seguinte forma: primeiro define-se o nível de importância de uma atividade em relação a um conjunto de aparelhos, em seguida define-se o nível de importância de cada aparelho para uma atividade específica.

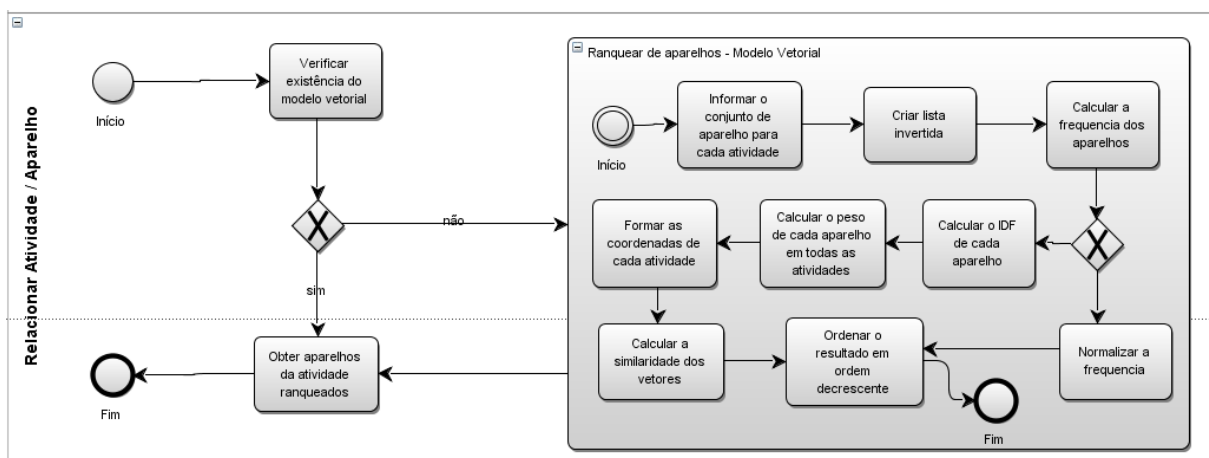


Figura 4.7. Processo de negócio do relacionamento entre atividade e aparelho.

O diagrama da Figura 4.7 descreve o processo de relação entre atividade e aparelho. O processo inicia com a verificação da existência ou não de um rank. Este rank é usado para estabelecer o nível de importância que um aparelho possui com relação a uma atividade e é definido por um modelo de espaço vetorial de similaridade apresentado a seguir. Caso não exista um rank para os aparelhos, o subprocesso de ranqueamento dos aparelhos baseado do modelo vetorial é iniciado. Caso contrário, o fluxo prossegue com a recuperação dos

aparelhos devidamente ranqueados e iniciando imediatamente o processo de recomendação de ações.

Quando o subprocesso de ranqueamento de atividade é iniciado, um conjunto de dados é organizado de forma que todos os aparelhos estejam postos em sequência e acompanhados das suas respectivas atividades, como mostra a Tabela 4.3.

Tabela 4.3. Organização dos dados por meio de uma lista invertida.

Aparelhos	Atividades
Aparelho 1	Atividade 1, Atividade 3
Aparelho 2	Atividade 1, Atividade 2, Atividade 3, Atividade 4
Aparelho 3	Atividade 1, Atividade 2, Atividade 3
Aparelho 4	Atividade 1

Os dados da Tabela 4.3 são estruturados em uma lista invertida. A partir da lista invertida, é possível saber o ranking das atividades em relação a um conjunto de aparelhos por meio de uma consulta. A lista invertida é usada para calcular a frequência dos aparelhos em todas as atividades.

Caso a intenção seja fazer o ranqueamento da atividade, o fluxo segue calculando o IDF dos aparelhos. O cálculo do IDF define a importância do aparelho sobre toda a coleção de atividades. Em seguida, para cada atividade da coleção atribui-se um peso para cada aparelho da consulta baseado do IDF obtido. O passo seguinte é formar um vetor para cada atividade baseado nos pesos de cada aparelho envolvido com a atividade. Assim, o nível de similaridade é obtido comparando-se os vetores de atividades com o vetor da consulta. O ranqueamento é estabelecido pela ordem de proximidade de cada vetor de atividade em relação ao vetor da consulta. A Tabela 4.4 mostra um exemplo do ranqueamento de atividades associadas com um conjunto de aparelhos.

Tabela 4.4. Exemplo do ranqueamento de atividades para uma consulta de aparelhos ligados.

Aparelhos	Aspirador de Pó, Enceradeira, Lâmpada da cozinha, Lâmpada da sala, Lavadora de Louça, Lavadora de Roupa, Secador de Roupa, Som.	Similaridade (%)
Atividades	Limpar a casa	99,99
	Lavar roupa	51,42
	Lavar louça	47,69
	Assistir TV	31,10
	Ouvir música	27,37

Como mostrado na Tabela 4.4, o cálculo da similaridade fornece um índice que indica quais atividades estão mais relacionadas com determinados aparelhos. Esse processo é usado para fazer previsões de qual atividade está sendo executada, quando um conjunto de aparelhos está ligado. O Algoritmo 2 apresenta o pseudocódigo do modelo vetorial proposto.

Algoritmo 2. Algoritmo que trata do modelo vetorial

-
1. **para cada atividade d na coleção, criar $A\{d\} = 0$ faça**
 2. **para cada aparelho t na consulta faça**
 3. recuperar a lista invertida para o aparelho t
 4. **para cada entrada $(d, f(d, t))$ na lista invertida faça**
 5. $A\{d\} = A\{d\} + \text{sim}(q, d, t)$.
 6. Identificar os k valores mais altos de acumuladores, onde k é o número de atividades
-

Em resumo, o algoritmo 2 cria os vetores vazios ($A\{d\}$) para cada atividade (linha 1). Em seguida recupera todos os aparelhos da lista invertida e calcula a similaridade entre os vetores de cada atividade em relação ao vetor do conjunto de aparelhos da consulta (linhas 2 a 5). Os aparelhos de maior similaridade são ordenados de forma decrescente, pois os aparelhos de maior similaridade são os mais importantes para uma determinada atividade (linha 6).

Caso a intenção seja fazer o ranqueamento dos aparelhos, o fluxo segue com a normalização do resultado das frequências sobre cada atividade. Primeiramente, calcula-se a frequência de cada aparelho da atividade reconhecida utilizando a Equação 2, explicada no Capítulo 2.

Em seguida, é necessário fazer a normalização dos valores para adequá-los no intervalo de 0% a 100%. A fórmula da normalização é dada por:

$$fn(d_i) = \frac{f_{i,j}}{\max(f_{i,j})} \quad (\text{Equação 5})$$

A normalização $fn(d_i)$ é aplicada sobre os aparelhos da atividade d_j , onde $f_{i,j}$ é a frequência do aparelho t_i e $\max(f_{i,j})$ é a maior frequência de todos os aparelhos de d_j .

O processo de ranqueamento de aparelhos define a intensidade da relação entre uma atividade e seu conjunto de aparelhos. Em outras palavras, para cada atividade A existe um conjunto de aparelhos T com pesos w . Com isso, é possível definir políticas de tratamentos diferenciados e descobrir aparelhos que estão desperdiçando energia elétrica apenas observando o valor do rank de cada aparelho. A Tabela 4.5 mostra um exemplo de ranqueamento de aparelhos definidos pela tarefa de normalização.

Tabela 4.5. Exemplo de ranqueamento de objetos associados a uma atividade.

Atividade: Limpar casa	Porcentagem (%)
Aspirador de pó	100
Enceradeira	100
Lavadora de louça	50
Lavadora de roupa	50
Lâmpada da sala	33
Som	25
Lâmpada do quarto	20
Lâmpada do banheiro	14
Lâmpada da área	12
Lâmpada da cozinha	9

4.2.5. Recomendação de ações

O diagrama da Figura 4.8 descreve o processo de recomendação de ações ao usuário. O processo inicia com uma análise das classes e tipos de aparelhos relacionados com a atividade reconhecida. Em seguida, os algoritmos de recomendação analisam os tipos de aparelhos para posteriormente fazerem recomendações ao usuário ou realizarem ações diretamente com os aparelhos.

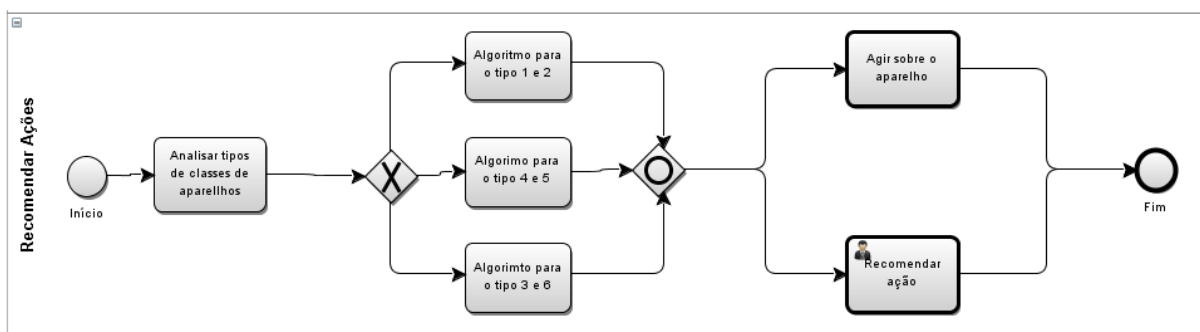


Figura 4.8. Processo de recomendação de ações por meio de algoritmos de recomendação.

Os tipos de aparelhos utilizados nas análises dos algoritmos de recomendação são baseados nas categorias de aparelhos e na necessidade ou não da presença do usuário. As categorias são definidas por grupos de aparelhos que operam de maneira diferente. Tais grupos possuem peculiaridades próprias das quais podem ser tratados de forma diferente. Essas particularidades são importantes para diferenciar a decisão dos algoritmos sobre cada aparelho melhorando a eficiência do HEMS. Niyato et al. [2011] definem três categorias para os aparelhos:

- 1) Aparelhos cujo consumo de energia é gerenciável: Essa categoria inclui aparelhos cujo consumo de energia varia com o tempo. Exemplo, máquina de lavar, geladeiras, TV, etc.
- 2) Aparelhos cujo consumo de energia é estável durante todo o seu ciclo de vida: Essa categoria inclui aparelhos cujo consumo de energia não varia com o tempo, permanecendo constante durante todo o processo. Por exemplo: luminárias.
- 3) Aparelhos cujo consumo não é gerenciável e nem estável: Essa categoria inclui aparelhos cuja variação de consumo é imprevisível. Exemplos, ar condicionados.

A categorização de aparelhos ajuda na criação de soluções mais precisas, uma vez que a compreensão dos padrões de consumo de cada categoria de aparelhos permite a elaboração de algoritmos mais eficientes com capacidade de tratamentos específicos. Com base nas categorias citadas acima, esta pesquisa sugere a criação de quatro categorias baseadas no tempo:

- 1) **Contínuo:** aparelhos que ficam ligados o tempo todo.
- 2) **Não Cronometrados:** aparelhos que não têm tempos definidos.
- 3) **Cronometrados:** aparelhos que têm tempo definido.
- 4) **Instantâneos:** aparelhos ficam ligados por curto período de tempo.

Essas categorias englobam os conceitos das categorias definidas por Niyato [2011], mas acrescentam na classificação o tempo de operação dos aparelhos. A Tabela 4.6 mostra exemplos de aparelhos de cada categoria.

Tabela 4.6. Exemplos de aparelhos elétricos separados por categorias.

Categoria	Aparelhos
Contínuo	Geladeira, freezer.
Não Cronometrado	TV, luz, ar condicionado, som, computador, piano.
Cronometrado	Máquina de lavar, micro-ondas.
Instantâneos	Fogão, liquidificador, fechadura elétrica.

A categoria dos aparelhos combinada com a necessidade ou não da presença do usuário da origem a um novo tipo de classificação de aparelhos com um nível maior de granularidade. Por exemplo, a máquina de lavar é um aparelho cronometrado que não

necessita da presença do usuário e o micro-ondas mesmo que seja um aparelho cronometrado, necessita da presença do usuário. A Tabela 4.7 mostra exemplos dos tipos de aparelhos.

Tabela 4.7. Tipos dos aparelhos.

Tipo	Presença Usuário	Categoria	Objetos
1	Sim	Não Cronometrado	Luz, TV, Ar-condicionado.
2	Sim	Cronometrado	Micro-ondas
3	Sim	Instantâneos	Liquidificador, Batedeira
4	Não	Cronometrado	Máquina de lavar
5	Não	Não Cronometrado	Aparelho de som
6	Não	Contínuo	Geladeira, freezer

Uma vez definida uma categorização para os aparelhos, é necessário explicar como os algoritmos de recomendações tomam decisões com base nessas categorias.

4.2.6. Detalhamento dos Algoritmos

No método AAEC foram definidos três algoritmos de recomendação. O primeiro deles realiza as recomendações com base nas atividades dos usuários e nos tipos de aparelhos. O segundo algoritmo faz recomendações com base no horário de pico e o terceiro algoritmo detecta desperdício de energia dos aparelhos contínuos e instantâneos caso haja alterações fora das especificações de fábrica dos aparelhos. Dependendo do resultado dos algoritmos, o método realiza ações nos aparelhos ou faz recomendações aos usuários, caso seja necessária de uma aprovação humana.

No caso das ações, o algoritmo é definido para desligar os aparelhos que não tem relação nenhuma com a atividade. No caso da recomendação, o algoritmo recomenda ao usuário realizar alguma ação. Por exemplo, quando o usuário está assistindo televisão na sala, o algoritmo questiona o usuário se a luz da sala deve permanecer ligada ou desligada. A ideia de recomendação é útil no sentido de evitar aborrecimento do usuário com uma ação indesejada.

No primeiro algoritmo de recomendação (Algoritmo 3), a decisão é obtida a partir da relação entre atividade/aparelho. Esse algoritmo trata os objetos dos tipos 1 e 2, ou seja, aqueles que requerem a presença do usuário e têm ou não um tempo definido para ficar ligados. O algoritmo inicia analisando o rank (definido pelo modelo vetorial proposto) de

cada aparelho envolvido com uma atividade reconhecida. Se o rank do aparelho for menor que 50%, o algoritmo realiza uma consulta ao usuário para saber se o aparelho pode ser desligado (linhas 4 a 10). Experimentos preliminares mostram que a maioria dos aparelhos que possuem similaridade abaixo de 50% possui relação fraca com a atividade (ver exemplo da Tabela 4.4). Em seguida, o algoritmo desliga todos os aparelhos que não possuem qualquer relação com a atividade e que necessitam a presença do usuário (linhas 11 a 15).

Algoritmo 3. Algoritmo de recomendação para os objetos dos tipos 1 e 2.

1. Obtêm os objetos do tipo 1 e 2 relacionados a atividade reconhecida.
 2. **para cada objeto da atividade X faça**
 3. rank = obtem rank do objeto Y
 4. **se rank > 0% e rank < 50% entao**
 5. **se objeto for do tipo 1 entao**
 6. **se usuário autorizar desligar o objeto entao**
 7. altera status do objeto
 8. **se objeto for do tipo 2 entao**
 9. **se usuário autorizar desligar o objeto entao**
 10. espera terminar o tempo programado para altera o status do objeto
 11. **senao se rank = 0% entao**
 12. **se objeto for do tipo 1 entao**
 13. desliga o objeto
 14. **senao se objeto for do tipo 2 entao**
 15. espera terminar o tempo programado para desligar o objeto
-

O processo de tomada de decisão do Algoritmo 4 é baseado na análise do horário de pico. Esse algoritmo trata os objetos que não necessitam da presença do usuário (tipos 4 e 5). Se o aparelho estiver sendo executado no horário de pico, o algoritmo faz uma recomendação para o usuário utilizar o aparelho fora do horário de pico (linhas 3 e 4). Caso não esteja no horário de pico e o rank do aparelho for menor que 50%, o algoritmo realiza uma consulta ao usuário para saber se o aparelho pode ser desligado devido a fraca relação com a atividade (linhas 5 e 6).

O horário de pico é um fator importante, pois muitas empresas distribuidoras de energia cobram preços diferenciados nesse horário. No Brasil, a tarifação diferenciada deve ser implantada nos próximos anos [Anatel, 2014]. A Tabela 4.7 mostra as possíveis combinações entre as categorias e a necessidade da presença ou não do usuário.

Algoritmo 4. Algoritmo de recomendação para os objetos dos tipos 4 e 5.

1. Obtêm os aparelhos do tipo 4 e 5 relacionados a atividade reconhecida.
 2. **para cada aparelho do tipo 4 e 5 faça**
 3. **se estiver no horário de pico e aparelho estiver ligado entao**
 4. recomendar uso fora do horário de pico
 5. **se não estiver no horário de pico e $rank \leq 50$ entao**
 6. recomendar que o usuário desligue o aparelho
-

O Algoritmo 5 trata dos aparelhos que necessitam ficar ligados continuamente (tipo 6) e aqueles que são caracterizados pelo período curto de tempo em que ficam ligados (tipo 3). O algoritmo monitora o consumo de energia dos aparelhos e compara com o consumo das especificações de fábrica. O objetivo é descobrir se o aparelho está ou não desperdiçando energia elétrica. Caso isso ocorra, o algoritmo informa o usuário sobre o mau funcionamento dos aparelhos (linhas 2 e 3).

Algoritmo 5. Algoritmo de recomendação para os objetos dos tipos 3 e 6.

1. **se aparelho for do tipo 3 e 6 entao**
 2. **se consumo aparelho > consumo das especificações de fábrica entao**
 3. Informa desperdício de energia para o usuário
-

Para aumentar o conforto do usuário o método AAEC oferece um conjunto de prioridades para os aparelhos. Por exemplo, se o usuário prefere ficar com a televisão ligada enquanto estiver cozinhando ou limpando a casa, mesmo que o método AAEC identifique essa ação como desperdício de energia, o algoritmo ignora a ação ou recomendação devido esta ser uma particularidade do usuário. As prioridades definidas pelo método AAEC são:

- 1 – Alta:** Realiza ação sem perguntar do usuário.
- 2 – Média:** Pede autorização do usuário.
- 3 – Baixa:** Não faz nada, apenas informa o usuário.

4.3. CONSIDERAÇÕES FINAIS

Em resumo, o método AAEC é uma solução de economia de energia baseada nas atividades dos usuários. A solução trata desde a coleta dos dados no ambiente até as tomadas de decisões pelos algoritmos. O método AAEC utiliza várias técnicas computacionais para alcançar seu objetivo. As técnicas utilizadas são: Algoritmos de aprendizagem de máquina, distância euclidiana, modelo vetorial e uso de estruturas básicas para auxiliar na decisão.

A árvore de decisão foi utilizada para reconhecer as categorias de atividades. Em seguida, o processamento é completado com análise da distância entre a média das atividades com o tempo de execução do sensor utilizando a técnica da distância euclidiana unidimensional. O modelo vetorial é utilizado para definir o nível de relação entre atividade/aparelho. Por fim, algoritmos de recomendação são utilizados para tomar decisões com base nesse nível de relação.

O método AAEC pode ser integrado com sistemas inteligentes de automação residencial ou os próprios sistemas de gerenciamento de energia para economizar energia elétrica em uma residência observando o comportamento dos usuários. A vantagem é que o usuário não terá esforço para mudar seus hábitos em relação à economia de energia, pois o método AAEC identificará os desperdícios e tomará as decisões necessárias.

Capítulo 5

Experimentos e Resultados

Este capítulo mostra em detalhes o funcionamento do método AAEC usando uma base de dados real fornecida pelo MIT (Massachusetts Institute Technologie). O Capítulo inicia detalhando o protocolo experimental usado nos experimentos incluindo, a descrição do cenário, a base de dados e o processo de construção da árvore de decisão. Os experimentos foram divididos em dois conjuntos: o primeiro mostra uma comparação entre alguns algoritmos de aprendizagem de máquina no processo de reconhecimento de atividade, comprovando a escolha do algoritmo de árvore de decisão para tratar esse problema. O segundo conjunto de experimentos é usado para validar o método AAEC. Os resultados apresentados correspondem à utilização do método AAEC para reconhecer as atividades dos usuários residentes em um apartamento na cidade de Massachusetts, EUA.

5.1. PROTOCOLO EXPERIMENTAL

5.1.1. Cenário

O cenário utilizado para validar o método AAEC foi um apartamento localizado em Massachusetts, EUA. No apartamento morava uma pessoa de 30 anos de idade que ficava em casa durante seu tempo livre. As atividades foram monitoradas 24 horas durante 14 dias. 77 sensores foram instalados em diversos locais como: fogão, armário, máquina de lavar, geladeira, portas, janelas, gavetas, micro-ondas, pias, chuveiro, tomada, lâmpadas, DVDs, aparelhos de som, lavador de louça cafeteira e outras localizações. A Figura 5.1 mostra imagens de alguns dos objetos em que os sensores foram instalados e a Figura 5.2 mostra o mapa com a localização dos sensores no apartamento.




Figura 5.1. Fotos de alguns locais onde os sensores estão instalados no apartamento.




Figura 5.2. Mapa do apartamento.

A Tabela 5.1 mostra cômodos e a localização dos sensores espalhado no apartamento. Os sensores foram instalados em locais onde o morador frequentemente realiza suas atividades. Por exemplo, nos dispositivos elétricos e móveis comuns.

Tabela 5.1. Disposição dos sensores no apartamento.

DISPOSITIVO	QUANTIDADE
Sala de estar	
Dvd	1
Lampada	1
Interruptor de luz	2
Cozinha	
Microondas	1
Torradeira	1
Geladeira	1

Freezer	1
Container de geladeira	3
Gaveta	7
Armário	14
Máquina de café	1
Containers	1
Bocas de Fogão	4
Forno	1
Porta	2
Coletor de lixo	1
Janela	1
Máquina de lavar roupa	1
Máquina de lavar louça	1
Interruptor de luz	2
Secador	1
Banheiro	
Descarga	1
Armário de medicamentos	2
Torneira de pia	2
Torneira de chuveiro	2
Armário	2
Gaveta	4
Porta	1
Exaustor	1
Quarto	
Lâmpada	1
Gavetas	5
Janela	1
Interruptor de luz	1
Porta joias	1
Escritório	
Porta	1
Gaveta	2
Interruptor de luz	1
Vestuário	
Porta	1
Closet	1
Interruptor de luz	1
Varanda	
Interruptor de luz	1
TOTAL	77

5.1.2. Detalhamento da Base de Dados

Os dados dos sensores foram coletados e armazenados em uma base de dados disponibilizada em [E. M. Tapia, 2004] [E. M. Tapia, 2003]. A base de dados contém dados dos sensores e das atividades realizadas pelo morador do apartamento. Os dados dos sensores estão organizados da seguinte forma:

- **Year_day:** representa o dia do ano, essa base foi extraída em 2003.
- **Week_day:** representa o dia da semana (1 = segunda e 7 = domingo).
- **Activation:** representa os segundos em que o sensor foi ativado começando de 12:00am.
- **Desactivation:** representa os segundo em que o sensor foi desativado começando de 12:am.
- **Interval:** representa o tempo em que o sensor ficou ativado em segundos.
- **Sensor_id:** representa a identificação do sensor.
- **Location:** representa o local na casa em que o sensor está instalado através de uma identificação.
- **Type:** representa o objeto em que o sensor está instalado.

As informações dos sensores são compostas por: a data/hora de ativação de cada sensor, o intervalo de ativação dos sensores, o objeto em que o sensor está instalado e localização do sensor no apartamento. A Tabela 5.2 mostra os detalhes dos valores de cada atributos.

Tabela 5.2. Detalhe dos dados de cada atributo.

Atributos	Valores
year_day	1 to 360
week_day	Friday,Monday,Saturday,Sunday,Thursday,Tuesday,wedsnesday
Activation, desactivation, interval	Seconds
location	Bathroom,Bedroom,Foyer,Kitchen,Living room,Office/study
type	Burner,Cabinet, Closet, Containers,Dishwasher,Door,Drawer, DVD, Exhaust Fan,Freezer, Garbage disposal,Jewelry box,Lamp,Laundry Dryer,Light switch,Medicine cabinet,Microwave, Oven,Refrigerator, Shower faucet,Sink faucet - cold, Sink faucet - hot,Toaster,Toilet Flush,Washing Machine

Além dos dados dos sensores, a base de dados também contém dados sobre as atividades realizadas no apartamento durante o período de estudos. Os dados das atividades estão organizados da seguinte forma:

- **Year_day:** representa o dia do ano, essa base foi extraída em 2003.
- **Week_day:** representa o dia da semana (1 = segunda e 7 = domingo).
- **Start_time:** representa os segundos em que o sensor foi ativado.

- **Activity_code:** representa o código da atividade. As atividades podem ser vistas na Tabela 20.
- **Subcategory_index:** representa o índice de cada subcategoria de atividade.
- **End_time:** representa os segundos em que o sensor foi desativado.

As informações das atividades são compostas pela data/hora em que a atividade foi iniciada e finalizada, assim como, a identificação de cada atividade. Nesta base, as atividades estão divididas em 7 grupos de categorias (cozinhar, trabalho doméstico, educação, sair de casa, lazer, movimentação e necessidades pessoais) e cada grupo possui um conjunto de atividades. A Tabela 5.3 mostra as atividades e seus respectivos grupos.

Tabela 5.3. Atividades com suas respectivas categorias.

Heading	subcategory	code	heading_id
Cooking	Preparingbeverage	80	8
Cooking	Preparingbreakfast	60	8
Cooking	Preparingdinner	70	8
Cooking	Preparinglunch	65	8
Cooking	Preparingsnack	75	8
Domesticwork	Cleaning	100	3
Domesticwork	Doinglaundry	105	3
Domesticwork	Puttingawaylaundry	110	3
Domesticwork	Puttingawaydishes	90	3
Domesticwork	Washingdishes	85	3
Domesticwork	Lawnwork	120	3
Domesticwork	Takingoutthetrash	115	3
Domesticwork	Puttingawaygroceries	95	3
Educational	Studying	125	4
Goingout	Goingouttowork	5	1
Goingout	Goingoutforshopping	155	1
Goingout	Goingoutforentertainment	145	1
Goingout	Goingouttoexercise	150	1
Goingout	Goingouttoschool	130	1
Leisure	Listeningtomusic	140	5
Leisure	WatchingTV	135	5
Moving	Moving the bathroom	170	10
Moving	Moving the Foyer	175	10
Moving	Moving the kitchen	165	10
Personalneeds	Eating	10	2
Personalneeds	Bathing	20	2
Personalneeds	Dressing	30	2
Personalneeds	Grooming	25	2
Personalneeds	Toileting	15	2
Personalneeds	Washinghands	35	2
Personalneeds	Takingmedication	40	2
Personalneeds	Resting	55	2

Personalneeds	Sleeping	45	2
Personalneeds	Talkingontelephone	50	2

A Figura 5.3 apresenta a distribuição das categorias de atividades encontradas na base de dados. Como observado na figura, a categoria de necessidades pessoais (PersonalNeeds) é a que possui a maior incidência de execução de atividades com 51% das ocorrências. Isso porque esta categoria engloba o maior número de atividades essenciais que são constantemente executadas por qualquer pessoa em uma residência, tais como tomar banho, comer, se vestir, dormir, ir ao banheiro etc. Os outros 49% são distribuídos entre as outras categorias de atividades, sendo 29% atribuído as atividades relacionadas aos trabalhos domésticos (Domesticwork).




Figura 5.3. Porcentagem das categorias de atividades encontradas na base MIT.

A base de dados do MIT foi estendida para conter informações sobre o consumo de energia de cada aparelho. Tais informações foram adicionadas manualmente com base na média das especificações de fábrica de cada aparelho. Por exemplo, uma cafeteira costuma gastar cerca 600 watts/horas, uma TV gasta cerca 85 watts/horas, etc. A Figura 5.4 mostra o consumo (watts/horas) de todos os aparelhos da base.




Figura 5.4. Consumo de cada aparelho.

5.1.3. Métricas

As métricas utilizadas para avaliar o método AAEC foram divididas em dois grupos. O primeiro grupo corresponde às métricas utilizadas na avaliação do reconhecimento de

atividade. O segundo grupo corresponde às métricas utilizadas para avaliar o quanto o método AAEC economizou de energia elétrica no ambiente estudado.

Vários algoritmos de aprendizagem de máquina foram testados com intuito de descobrir o algoritmo que melhor se adéqua ao reconhecimento das atividades na base do MIT. Os algoritmos foram testados utilizando a técnica de validação cruzada (do inglês, cross validation) [Kohavi, 1995]. Esta técnica tem como objetivo a avaliação da acurácia de um determinado modelo de predição.

Foi empregada a validação cruzada com 10 partições para todos os classificadores utilizados no teste. As partições são randomicamente divididas em n grupos de dados de tamanhos iguais. A cada iteração, n-1 grupos são combinados para compor o conjunto de treino, enquanto que o grupo restante é utilizado para testar o modelo gerado. Esse processo é repetido n vezes, sendo que cada um dos grupos deverão ser escolhidos como base de teste uma vez. No final, a média de classificação obtida nas n bases de testes é calculada. A escolha do melhor algoritmo para a base do MIT foi baseado nas seguintes métricas:

- **Precisão:** definida como a razão entre a quantidade de categorias corretamente classificadas (verdadeiros positivos) e a quantidade de categorias erroneamente classificadas (falsos positivos) mais a quantidade de categorias corretamente classificadas (verdadeiros positivos).
- **Revocação:** definida como a razão entre a quantidade de categorias corretamente classificadas (verdadeiros positivos) e a quantidade total da população de cada categoria.
- **Acurácia:** define o quão próximo o modelo está da perfeição. A acurácia é medida pela média ponderada da precisão e seu inverso, assim como, a média ponderada da revocação e seu inverso.

Em relação ao consumo de energia, duas métricas foram utilizadas para avaliar o método AAEC. A primeira trata do consumo de energia por atividade e a segunda trata da análise do consumo diário de um conjunto de atividades.

- **Consumo de energia por atividade:** define a economia de energia baseada no tempo médio em que cada atividade costuma ser executada. A análise do consumo é feita em *watts* por horas.

- **Consumo diário de energia:** define a economia de energia durante um período de tempo de 24 horas. A análise do consumo é feita em *watts* por horas.

Ambas as análises observaram a execução das atividades dentro e fora dos horários de pico. Os horários de pico foram definidos entre às 11:00 e 13:30 e de 18:00 às 20:30 horas.

5.2. RESULTADOS

Os experimentos realizados sobre a base MIT foram divididos em dois cenários. O primeiro mostra uma comparação entre algoritmos de aprendizagem de máquina no processo de reconhecimento de atividade, comprovando a escolha do algoritmo de árvore de decisão. O segundo conjunto de experimentos é usado para validar o método AAEC no sentido de economia de energia. Este experimento observa o consumo de energia por atividade sem e com a utilização do método AAEC e também o consumo de energia da rotina diária do morador do apartamento.

5.2.1. Comparação dos Algoritmos de Aprendizagem

Comparações foram feitas com vários algoritmos de aprendizagem de máquina para avaliar qual deles é mais adequado ao problema de reconhecimento de atividades para a base dados utilizada. A Tabela 5.4 mostra os resultados para um conjunto de algoritmos utilizados nos testes.

Tabela 5.4. Algoritmos de aprendizagem usados no reconhecimento das categorias das atividades.

Algoritmo	Acertos	Erros	Acurária (%)	Precisão (%)	Revocação (%)
Bayes Network	2975	8	99,7318	99,7	99,7
Naive Bayes	2269	714	76,0644	80,5	76,1
Logistic Regression	2514	469	84,2776	83,8	84,3
J48	2980	3	99,8994	99,9	99,9
RandomTree	2982	1	99,9665	99,99	99,99
Best-First Decision Tree	2980	3	99,8994	99,9	99,9
Random forest	2982	1	99,9665	100	100
IBk, k=1	2972	11	99,6312	99,6	99,6
Kstar Beta Verion	2884	99	96,6812	96,8	96,7
Decision Table	2980	3	99,8994	99,9	99,9
Suport Vector Machine	2364	619	79,2491	81	72,8

Como pode ser observado na Tabela 5.4, a precisão de 99,96% do algoritmo de árvore de decisão *RandomTree*, pode caracterizar um super ajuste nos dados (*overfitting*) devido ao fato de ter poucas variáveis e conseqüentemente ser considerado um problema de fácil aprendizagem. Entretanto, o emprego de aprendizagem de máquina neste problema é importante, pois permite que as regras de reconhecimento de categorias sejam feitas automaticamente, evitando que um programador possa implementá-las de forma manual. Além disso, essa característica permite que as regras possam ser alteradas ao logo do tempo como, por exemplo, com o surgimento de novas categorias de atividades.

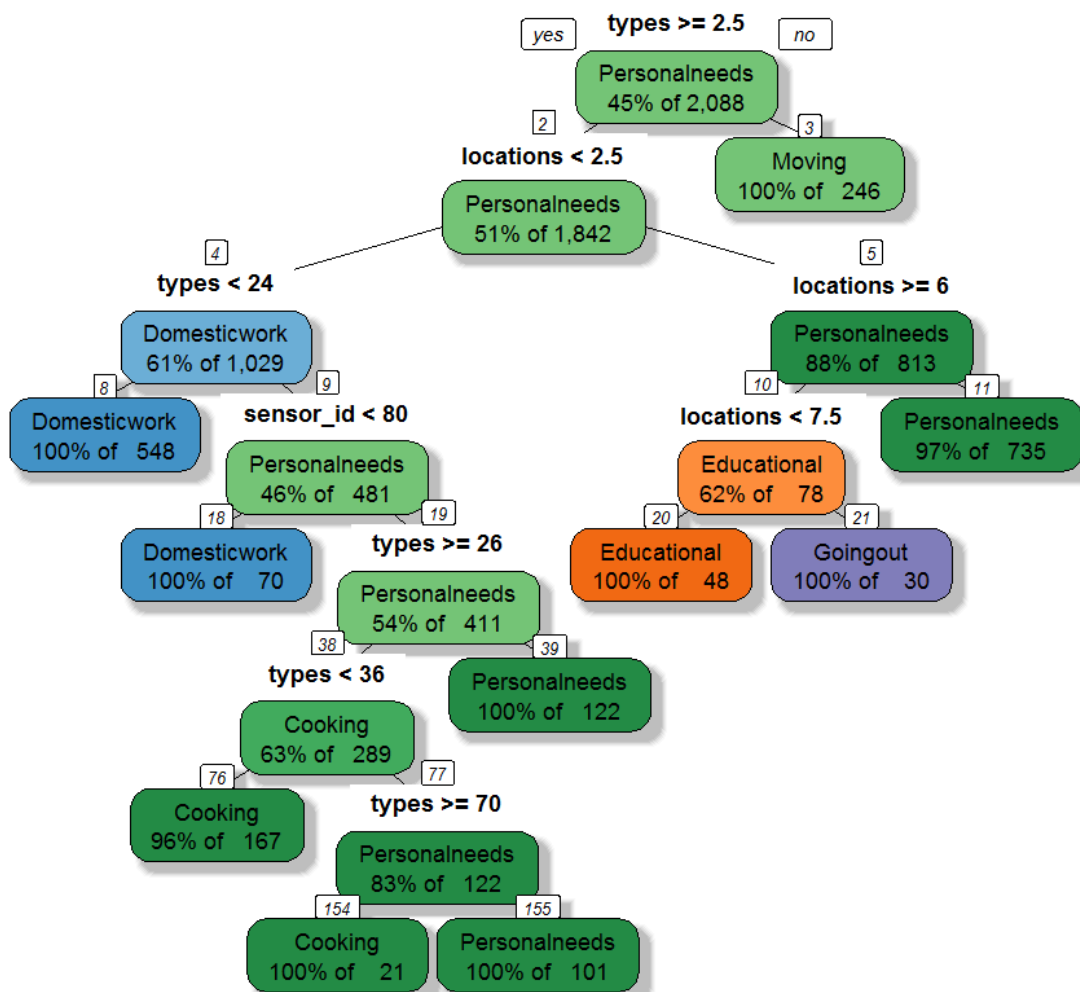


Figura 5.5. Árvore de decisão para reconhecimento de categoria de atividades.

Os testes foram realizados utilizando a ferramenta WEKA². O algoritmo foi executado com o seguinte comando: `weka.classifiers.trees.RandomTree -K 0 -M 1.0 -S 1`. A Figura 5.5 mostra o conjunto de regras geradas pelo algoritmo *RandomTree*. Tais regras são compostas pelo objeto em que o sensor está instalado e pela localização do objeto no ambiente. O

² <http://www.cs.waikato.ac.nz/ml/weka/>

caminhamento por essas regras permitem reconhecer qual categoria de atividade em que determinada amostra pertence.

5.2.2. Economia de Energia

Esta seção mostra o quanto o método AAEC economiza de energia elétrica no apartamento estudado. Os testes de consumo de energia foram divididos em dois cenários. O primeiro cenário trata do consumo individual de cada atividade com seus respectivos aparelhos sendo executadas dentro e fora do horário de pico. O segundo cenário analisa algumas atividades que foram executadas no apartamento em um período de 24 horas.

Como os dados foram coletados em um período de 14 dias, os testes realizados nesta pesquisa não levam em consideração o consumo mensal. Entretanto, o consumo de energia dos aparelhos pode ser facilmente previsto com base no conhecimento do consumo médio individual de cada aparelho. As previsões de consumo de energia para dias, semanas, meses e anos, pode ser obtida pela Equação 6.

$$\text{Consumo (kWh)} = \frac{\text{potência (W)} * N^{\circ} \text{ horas} * N^{\circ} \text{ de dias de uso ao mês}}{1000} \quad (\text{Equação 6})$$

Por exemplo, uma máquina de lavar gasta cerca de 500 *watts* por hora. Uma pessoa utiliza em média uma máquina de lavar 12 dias no mês com duração de 1 hora por cada operação. Fazendo o cálculo desses valores na Equação 6, o consumo da máquina de lavar seria 6 kWh no mês. Assim, esta conta pode prever o consumo de qualquer aparelho para qualquer tempo do futuro. A Tabela 5.5 mostra a previsão mensal de consumo dos aparelhos da base.

Tabela 5.5. Previsão mensal de consumo dos aparelhos elétricos.

Aparelhos	Potência média (Watts)	Tempo médio de uso	Dias de uso no mês	Total (kWh)
Floor polisher	500	1 h	4	2
Refrigerator	200	10 h	30	60
Freezer	400	10 h	30	120
Clothes Dryer	3500	1 h	12	42
Dish Washer	1500	40 min	30	30
Coffee	1000	30 min	30	15
Computer	250	2 h	30	15
Stove	1500	30 min	20	15
Lamp	100	5 h	30	15
Electric Shower	3500	8 min	30	14
TV	90	5 h	30	13,5

Microwave	1300	20 min	30	13
Fan	100	4 h	30	12
Washer Machine	1500	30 min	12	9
Radio	8	24 h	30	5,76
Vacuum Cleaner	1000	20 min	15	5
Toaster	800	10 min	30	4
Sound	20	2 h	15	0,6
Clothes Iron	1000	1 h	12	12
Air Condicional	4000	2 h	30	240

5.2.2.1 Economia de energia por atividade

Esta seção apresenta os resultados de um conjunto de atividades executadas dentro e fora dos horários de pico. A Tabela 5.6 apresenta o consumo de energia total dos aparelhos relacionados com cada atividade. O cálculo do consumo de energia é obtido considerando o tempo médio em que cada atividade leva para ser executada. A avaliação baseada no tempo médio de execução das atividades foi escolhida devido à taxa de economia de energia obtida pela utilização do método AAEC ser sempre proporcional ao número de execução de cada atividade.

Tabela 5.6. Consumo de energia total das atividades para os cenários com e sem o método AAEC.

Cenário	Consumo de energia das atividades sem o Método AAEC (Watts/Hora)	Consumo de energia das atividades com o Método AAEC (Watts/Hora)	Taxa de Economia de Energia (%)
Horários de Pico	28117,48	18045,55	35,82
Fora do Horário de Pico	28117,48	20736,77	26,24

Como pode ser observado, na Tabela 5.6, a taxa de economia de energia proporcionada pela utilização do método AAEC foi de 35,82% nas atividades executadas nos horários de pico e 26,24% nas atividades executadas fora do horário de pico. Os dados apresentados na coluna 2 são iguais pois referem-se ao consumo das atividades sem aplicação do método AAEC.

A Figura 5.6 mostra um exemplo do consumo de energia de algumas atividades executadas no horário de pico. Para cada atividade é obtido o consumo de energia (medido em *watts/hora*) de todos os objetos relacionados com a atividade.

Como pode ser observado, algumas atividades tiveram um percentual de diminuição do consumo de energia devido a execução das ações recomendadas pelo método AAEC. A atividade Lavar Roupa tem dois aparelhos do tipo 4 relacionados (Máquina de Lavar e

Secadora) e como esta atividade foi programada para ser executada no horário de pico, o algoritmo recomendou ao usuário a execução desta atividade fora do horário de pico, o que justifica o não consumo de energia para esta e outras atividades como Lavar Louça e Ouvir Música nesse intervalo de tempo.

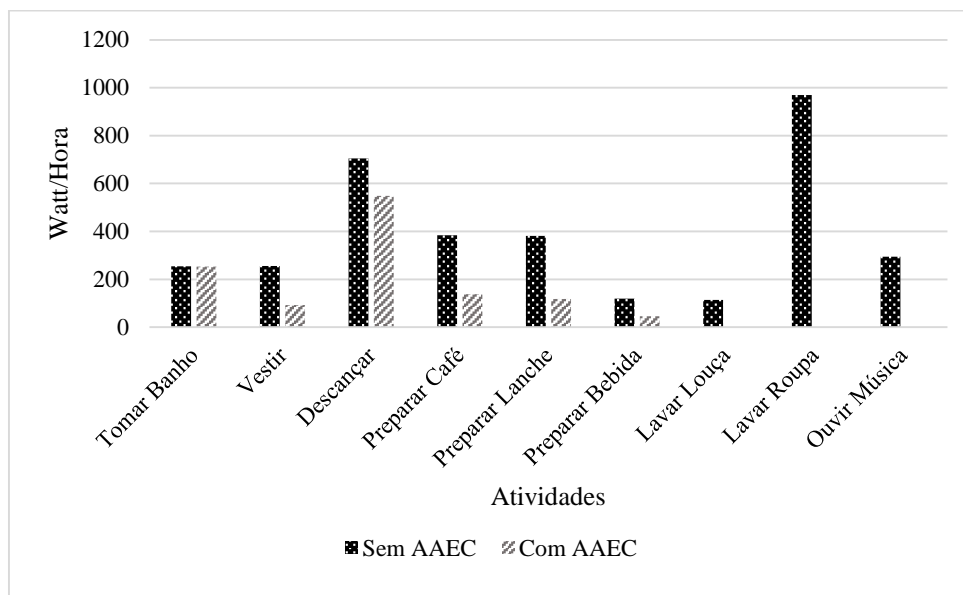


Figura 5.6. Consumo de cada atividade sendo executada no horário de pico.

Além do consumo normal dos aparelhos, também foi analisado o consumo dos aparelhos que possuem o modo *standby*. Durante a execução das atividades, os aparelhos no modo *standby* gastaram cerca de 20 mil *watts* sem atuação do método AAEC e quando o método AAEC foi aplicado, o consumo diminuiu para cerca de 4 *watts* tendo uma economia de 80,17%. Isso significa que o método AAEC sugeriu o desligamento de vários aparelhos.

O consumo de aparelhos no modo *Standby* gasta em média 7% do consumo normal. Essa taxa faz diferença no bolso do consumidor no final mês, por exemplo, uma televisão consome em média 90W quando ligada, se permanecer ligada durante 1 hora todo dia o consumidor paga R\$ 0.55 e no modo *Standby* consome em média 20W, gerando um custo de R\$ 0.12.

5.2.2.2. Consumo Diário

Esta seção apresenta os resultados obtidos pelo método AAEC sobre as atividades realizadas pelo usuário residente do apartamento. A Figura 5.7 mostra o intervalo de tempo em que algumas das atividades foram realizadas no dia 30/03/2003.

Como pode ser observado, o usuário realizou cinco atividades durante o dia, sendo que cada atividade foi executada em um horário específico. Por exemplo, a atividade “ir ao banheiro” foi realizada sete vezes durante o dia e demorou em média 10 minutos.

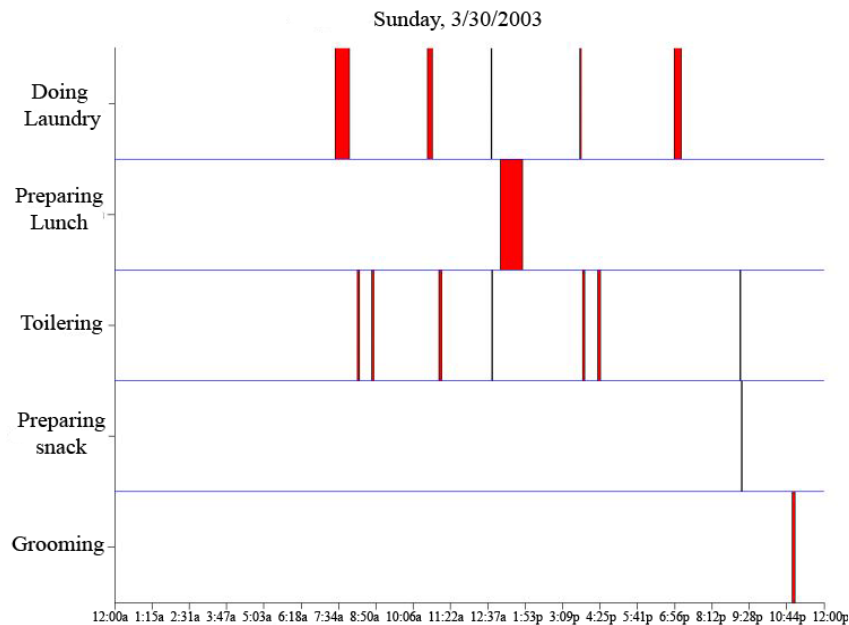


Figura 5.7. Período de realização das atividades no dia 30 de março de 2003.

A Figura 5.8 mostra o consumo de energia dos aparelhos envolvidos com as atividades desenvolvidas no dia 30/03/2003. A linha contínua representa o consumo de energia medido sem o método AAEC e a linha tracejada representa o consumo de energia das atividades com a utilização do método AAEC.

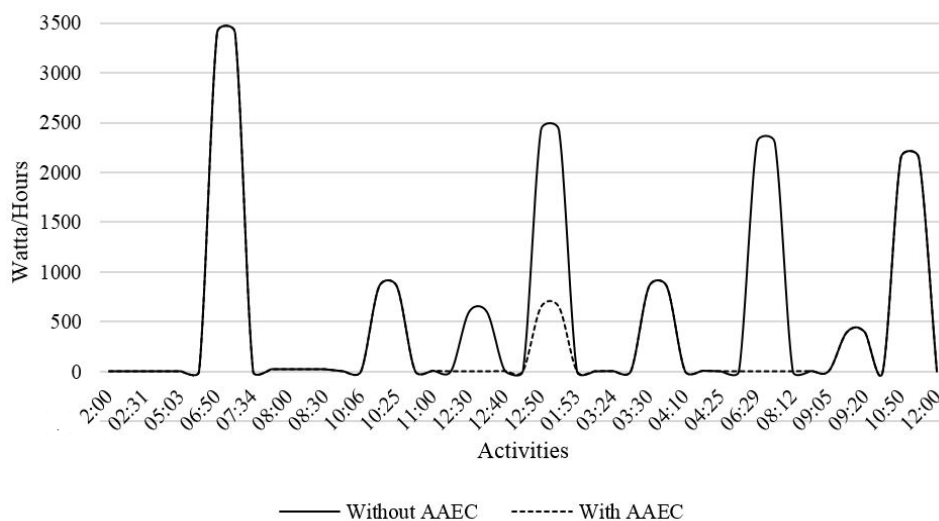


Figura 5.8. Consumo de energia com e sem o método AAEC no domingo do dia 30/03.

A partir deste quadro de apresentação do consumo de energia percebe-se que a linha tracejada acompanha a linha contínua com uma leve queda na taxa de economia de energia ao longo dos horários fora do pico. Por outro lado, quando o horário de pico é atingido, essa taxa cai abruptamente. A explicação para esse comportamento é que durante este período, o usuário somente realizou a atividade Lavar Roupa e como esta atividade não necessita da presença do usuário, o método AAEC recomenda sua execução fora do horário de pico. É importante salientar que a taxa de economia de energia varia de acordo com a rotina e costumes dos usuários.

5.3 CONSIDERAÇÕES FINAIS

O método AAEC introduziu uma nova forma de economizar energia elétrica utilizando TICs. Economizar energia elétrica com base nas atividades dos usuários é o principal objetivo deste método. Para atingir este objetivo, experimentos foram realizados com dados de um ambiente real. O uso de uma base de dados real reflete bem a realidade da maioria das pessoas no tocante a realização das atividades executadas diariamente em uma residência. Os resultados mostraram que o método proposto conseguiu atingir o objetivo proposto de forma eficiente conseguindo economizar cerca de 35% de energia elétrica.

O emprego de algoritmos de aprendizagem de máquina se mostrou eficiente no reconhecimento de categoria de atividades. Nesta base de dados o melhor algoritmo foi a árvore de decisão, acertando quase 100% das categorias de atividades. O algoritmo errou apenas uma vez, confundindo uma instancia de necessidades pessoais com trabalhos domésticos.

O reconhecimento da atividade do usuário e sua relação com aparelhos elétricos permite ter informações mais precisas do consumo de energia, uma vez que se tem informações individuais de cada aparelho elétrico por atividade. Isso permite um controle maior do consumo de energia no ambiente e, conseqüentemente, maior facilidade na identificação de desperdícios de energia elétrica.

De maneira geral, a inclusão do método AAEC se mostrou uma boa solução de economia de energia em ambientes inteligentes. A sua implementação em sistemas de automação residencial, melhora a qualidade de vida das pessoas, diminui custos e contribui com a conservação do meio ambiente.

Capítulo 6

Considerações Finais e Trabalhos Futuros

6.1 CONSIDERAÇÕES FINAIS

Esta pesquisa propôs um método para economizar energia elétrica em ambientes inteligentes por meio do reconhecimento de atividade do usuário. A ideia parte do princípio de que o comportamento das pessoas influencia diretamente no consumo de energia elétrica. A proposta resolve o problema proporcionado pelos maus hábitos dos usuários no que diz respeito ao consumo desnecessário de energia elétrica, de forma que seja possível economizá-la por meio de tecnologias computacionais ligadas a IoT.

O método AAEC segue um conjunto de etapas que inicia desde a coleta de dados até a recomendação de ações para o usuário economizar energia. A primeira etapa requer que o ambiente seja equipado com recursos tecnológicos que permitam a extração de dados do ambiente físico. Os dados capturados são armazenados em uma base de dados para posterior análise pelo método proposto. Esta pesquisa utilizou uma base de dados real que contém dados de sensores de um apartamento localizado no MIT.

A segunda etapa, responsável pelo reconhecimento de atividade, foi dividida em duas fases. Na primeira fase utilizou-se um algoritmo de aprendizagem de máquina para reconhecer as categorias de atividades. Na segunda fase utilizou-se a distância euclidiana para reconhecer as atividades de determinada categoria.

Na terceira etapa, um algoritmo de ranqueamento foi utilizado para descobrir o nível de relação que um aparelho tem com determinada atividade. Essa relação é usada para identificar situações de desperdício de energia e melhorar a acurácia de recomendações ao usuário. Por exemplo, se um aparelho não tem relação com uma atividade em execução, os algoritmos realizam ações necessárias para impedir que este aparelho continue ligado.

Por último, foram definidas recomendações com base nos tipos de aparelhos. Essa classificação, foi originada pela combinação entre as classes de aparelhos e a necessidade ou não da presença do usuário para permanecerem ativos. Isso influencia na criação de algoritmos específicos que fazem tratamentos diferenciados para cada aparelho. Tais tratamentos englobam: ações de alteração de status automático dos aparelhos, programação de tempo para que os aparelhos regulares fiquem ligados e monitoramento de consumo para posterior comparação com especificações de fábrica.

A principal dificuldade deste trabalho foi encontrar uma base de dados real que atendesse às necessidades dessa pesquisa. Felizmente, foi encontrado uma base de dados pública localizada no MIT que continha dados de atividades dos usuários e aparelhos elétricos. Também houve dificuldade de comparação de trabalhos, pois a maioria dos testes nessa área de pesquisa são feitos em bases de dados que não são divulgadas. Além disso, na literatura não foi encontrado nenhum trabalho com comparações entre soluções.

Este trabalho obteve tanto contribuições sociais quanto científicas: A contribuição social ajuda no desenvolvimento de uma sociedade mais sustentável com economia de energia elétrica nas residências. A contribuição científica se refere à criação de um método que economiza energia elétrica com base no comportamento do usuário. Além disso, a pesquisa introduziu uma forma de reconhecimento de atividade utilizando algoritmo de aprendizagem de máquina e distância euclidiana, modelo vetorial para fazer ranqueamento de atividades em relação aos aparelhos e novos algoritmos de recomendação baseados em categoria de aparelhos.

Assim, conclui-se que os resultados e os experimentos demonstram a viabilidade da aplicação do método em ambientes reais. A grande motivação é que nesses ambientes a economia de energia será bem maior do que os resultados alcançados nessa pesquisa, pois na realidade o usuário deixa muitos aparelhos ligados desnecessariamente e a aplicação do método AAEC refletirá diretamente na economia de dinheiro sobre conta de energia no final do mês.

6.2. TRABALHOS FUTUROS

Soluções de economia de energia baseadas no comportamento do usuário será parte integrante de sistemas inteligentes no futuro. Diante desse fato, como trabalhos futuros,

pretende-se aplicá-lo em vários ambientes (residências, escritórios, hospitais, edifícios, etc) a fim de avaliar o impacto da solução nesses ambientes. Em especial, essa solução pode ser aplicada na área de *healthcare*, uma vez que o reconhecimento de atividade é bastante explorada nesta área.

Além disso, este trabalho pode ser estendido com a implementação da identificação do usuário. Essa extensão serve para o controle do consumo de energia de cada usuário que atua no ambiente, permitindo traçar perfis e descobrir usuários que desperdiçam mais energia. Outra ideia seria acrescentar ao método AAEC, o reconhecimento de atividades utilizando os sensores dos *smartphones* como fonte de dados.

Referências

- C. Perera, S. Member, A. Zaslavsky, and P. Christen, "Context Aware Computing for The Internet of Things : A Survey," *Commun. Surv. Tutorials*, IEEE, vol. PP, no. 99, pp. 1–41, 2013.
- C. F. Lai, Y.-X. Lai, L. T. Yang, and H.-C. Chao, "Integration of IoT Energy Management System with Appliance and Activity Recognition," *2012 IEEE Int. Conf. Green Comput. Commun.*, pp. 66–71, Nov. 2012.
- C. Ramos, P. Juan, and C. Augusto, "Ambient Intelligence — the Next Step for Artificial Intelligence," *Intell. Syst. IEEE*, vol. 23, no. 2, pp. 15–18, 2008.
- EPE, *Projeção da demanda de energia elétrica*. Rio de Janeiro. 2013.
- European Commission, "Internet of things in 2020 road map for the future," Working Group RFID of the ETP EPOSS, Tech. Rep., May 2008, http://ec.europa.eu/information_society/policy/rfid/documents/iotprague2009.pdf [Accessed on: 2011-06-12].
- K. Ashton, "That 'internet of things' thing in the real world, things matter more than ideas," *RFID Journal*, June 2009, <http://www.rfidjournal.com/article/print/4986> [Accessed on: 2012-07-30].
- M. Castro, A. J. Jara, and A. F. G. Skarmeta, "Smart Lighting Solutions for Smart Cities," 2013 27th Int. Conf. Adv. Inf. Netw. Appl. Work., pp. 1374–1379, Mar. 2013.
- M. Grassi, M. Nucci, and F. Piazza, "Towards an ontology framework for intelligent smart home management and energy saving," *2011 IEEE Int. Symp. Ind. Electron.*, pp. 1753–1758, Jun. 2011.
- M. Weng, C. Wu, and C. Lu, "Context-aware home energy saving based on Energy-Prone Context," *Intell. Robot. Syst. (IROS), 2012 IEEE/RSJ Int. Conf.*, pp. 5233–5238, 2012.
- P. Guillemin and P. Friess, "Internet of things strategic research roadmap," The Cluster of European Research Projects, Tech. Rep., September 2009, http://www.internet-of-things-research.eu/pdf/IoT_Cluster_Strategic_Research_Agenda_2009.pdf.
- S. Lee, G. Lin, W. Jih, and J. Y. Hsu, "Appliance Recognition and Unattended Appliance Detection for Energy Conservation," *Assoc. Adv. Artif. Intell.*, pp. 37–44, 2010.

- The world bank, back ground paper “Residential Consumption Of Electricity In India Documentation Of Data And Methodology,” July 2008.
- Z. Cheng and Y. Ozawa, “A location-aware lifestyle improvement system to save energy in smart home,” 4th Int. Conf. Aware. Sci. Technol., pp. 109–114, Aug. 2012.
- T. Lu and W. Neng, “Future internet: The internet of things,” in 3rd International Conference on Advanced Computer Theory and Engineering(ICACTION), vol. 5, August 2010, pp. V5–376–V5–380.
- J. Yick, B. Mukherjee, and D. Ghosal, “Wireless sensor network survey,” *Comput. Networks*, vol. 52, pp. 2292–2330, 2008.
- T. A. Nguyen and M. Aiello, “Energy intelligent buildings based on user activity: A survey,” *Energy Build.*, vol. 56, pp. 244–257, Jan. 2013.
- D. Niyato, L. Xiao, and P. Wang, “Machine-to-machine communications for home energy management system in smart grid,” *Commun. Mag. IEEE*, no. April, pp. 53–59, 2011.
- D. Bonino, F. Corno, and F. Razzak, “Enabling machine understandable exchange of energy consumption information in intelligent domotic environments,” *Energy Build.*, vol. 43, no. 6, pp. 1392–1402, Jun. 2011.
- A. Rossello-Busquet, L. J. Brewka, J. Soler, and L. Dittmann, “OWL Ontologies and SWRL Rules Applied to Energy Management,” 2011 UkSim 13th Int. Conf. Comput. Model. Simul., pp. 446–450, Mar. 2011.
- A. R. Devidas and M. V. Ramesh, “Design and Implementation of User Interactive Wireless Smart Home Energy Management System” *Adv. Comput. Commun. Informatics (ICACCI), 2013 Int. Conf.*, pp. 626–631, 2013.
- Erol-Kantarci, M., Mouftah, H.T., “Wireless Sensor Networks For Domestic Energy Management In Smart Grids”, *Communications (QBSC), 2010 25th Biennial Symposium on*, pp. 63 – 66, 2010.
- D. Nagesh, “A real-time architecture for smart energy management,” *Innov. Smart Grid Technol.*, pp. 1–4, 2010.
- H. Vogt, H., Weiss, “A Client Architecture for Market-Based Grid Integration of Smart Environments,” *Pervasive Comput. Commun. Work. (PERCOM Work. 2010 8th IEEE Int. Conf.*, pp. 642–647, 2010.
- S. Meyer and K. Sperner, “Towards modeling real-world aware business processes,” *Proc. Second Int. Work. Web Things*, no. June, pp. 1–6, 2011.

- Schmidt, G. Business Process Management Common Body of Knowledge- BPM CBOK: Leitfaden für das Prozessmanagement herausgegeben von der European Association of Business Process Management, 2009.
- O. M. G. D. Number and A. S. Files, "Business Process Model and Notation (BPMN)," no. January, 2011.
- F. J. Ordóñez, J. A. Iglesias, P. de Toledo, A. Ledezma, and A. Sanchis, "Online activity recognition using evolving classifiers," *Expert Syst. Appl.*, vol. 40, no. 4, pp. 1248–1255, Mar. 2013.
- JehadSarkar, A., Lee, Y.-K., & Lee, S. (2010). A smoothed naive Bayes-based classifier for activity recognition. *Iete Technical Review*, 27, 107.
- Cook, D. J., & Schmitter-Edgecombe, M. (2009). Assessing the quality of activities in a smart environment. *Methods of Information in Medicine*, 48, 480–485.
- N. Brgulja, R. Kusber, and K. David, "A Data Mining Framework for Activity Recognition In Smart Environments," *2010 Sixth Int. Conf. Intell. Environ.*, pp. 140–145, Jul. 2010.
- Inteligência Artificial: Uma Abordagem de Aprendizagem de Máquina / Katti Faceli... [et al.]. – Rio de Janeiro : LTC, 2011.
- Mitchell, T. (1997). *Machine Learning*. McGraw-Hill, 1. Ed.
- K. Ko and K. Sim, "Development of Context Aware System based on Bayesian Network driven Context Reasoning Method and Ontology Context Modeling," pp. 2309–2313, 2008.
- G. Singla, D. J. Cook, and M. Schmitter-Edgecombe, "Recognizing independent and joint activities among multiple residents in smart environments.," *J. Ambient Intell. Humaniz. Comput.*, vol. 1, no. 1, pp. 57–63, Mar. 2010.
- S. Huang, T. Wu, H. Chu, and G. Hwang, "A Decision Tree Approach to Conducting Dynamic Assessment in a the entropy of feature A_k is calculated as," *Fifth IEEE Int. Conf. Wireless, Mobile, Ubiquitous Technol. Educ.*, pp. 89–94, 2008.
- G J.R. Quinlan, *Induction of decision trees*, *Machine Learning* (1986).
- L. Breiman, J.H. Friedman, R.A. Olshen, C.J. Stone, *Classification and Regression Trees*, Wadsworth Inc., 1984.
- J.R. Quinlan, *C4.5 Programs for Machine Learning*, Morgan Kaufmann, San Mateo, 1993.
- "Sistemas inteligentes: fundamentos e aplicações", organização Solange Oliveira Rezende, Barueri SP : Manole, 2005.

- Ricardo Baeza-yates, Berthier Ribeiro-neto, "Recuperação de Informação - Conceitos e Tecnologia das Máquinas de Busca", BOOKMAN, 2013, pg. 614.
- OLIVEIRA, Elias. et al. Um Modelo Algébrico para Representação, Indexação e Classificação Automática de Documentos Digitais. *Revista Brasileira de Biblioteconomia e Documentação-RBBD*, São Paulo, v. 3, n. 1, pp.73-98. 2007.
- FERNEDA, Edberto. *Recuperação de Informação: Análise sobre a contribuição da Ciência da Computação para a Ciência da Informação*. 2003. 137f. Tese (Doutorado em Ciências da Comunicação). Escola de Comunicação e Artes, Universidade de São Paulo - USP. 2003.
- D. Bonino and F. Corno, "DogOnt - Ontology Modeling for Intelligent Domotic Environments," *Energy Build.*, pp. 790–803, 2008.
- A. Rossello-Busquet, L. J. Brewka, J. Soler, and L. Dittmann, "OWL Ontologies and SWRL Rules Applied to Energy Management," 2011 *UkSim 13th Int. Conf. Comput. Model. Simul.*, pp. 446–450, Mar. 2011.
- Z. Yu, F. Haghghat, B. C. M. Fung, and H. Yoshino, "A decision tree method for building energy demand modeling," *Energy Build.*, vol. 42, no. 10, pp. 1637–1646, Oct. 2010.
- P. E. Danielsson, "Euclidean distance mapping," *Comput. Graphic,s Image Processing*, vol. 14, pp. 227-248, 1980.
- E. M. Tapia, S. S. Intille, and K. Larson, "Activity recognition in the home setting using simple and ubiquitous sensors," in *Proceedings of PERVASIVE 2004*, vol. LNCS 3001, A. Ferscha and F. Mattern, Eds. Berlin Heidelberg: Springer-Verlag, 2004, pp. 158-175.
- E. M. Tapia, *Activity Recognition in the Home Setting Using Simple and Ubiquitous Sensors*. M.S. Thesis Media Arts and Sciences, Massachusetts Institute of Technology, September 2003.
- E. M. Tapia, N. Marmasse, S. S. Intille, and K. Larson, "MITes: Wireless portable sensors for studying behavior," in *Proceedings of Extended Abstracts Ubicomp 2004: Ubiquitous Computing*, 2004.
- M. J. Kofler, C. Reinisch, and W. Kastner, "A semantic representation of energy-related information in future smart homes," *Energy Build.*, vol. 47, pp. 169–179, Apr. 2012.
- The OSGi Alliance (2003), *OSGi Service Platform*, Release 3, IOS Press, p. 604.
- Harrison, Colin, and Ian Abbott Donnelly. "A theory of smart cities." *Proceedings of the 55th Annual Meeting of the ISSS-2011*, Hull, UK. Vol. 55. No. 1. 2011.

- B. Najafi, K. Aminian, A. Paraschiv-Ionescu, F. Loew, C. Bula, and P. Robert, "Ambulatory system for human motion analysis using a kinematic sensor: monitoring of daily physical activity in the elderly," *Biomedical Eng.*, vol. 50, no. 6, pp. 711–723, 2003.
- American Psychiatric Association, *Diagnostic and Statistical Manual of Mental Disorders DSM-IV-TR*. American Psychiatric Publishing, July 1994.
- Vázquez, Félix Iglesias, Wolfgang Kastner, and Christian Reinisch. "Impact of user habits in smart home control." *Emerging Technologies & Factory Automation (ETFA)*, 2011 IEEE 16th Conference on. IEEE, 2011.
- M. Ermes, J. Parkka, J. Mantyjarvi, and I. Korhonen, "Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions," *TITB*, vol. 12, no. 1, pp. 20–26, Jan. 2008.
- L. Atzori, A. Iera, and G. Morabito, "The internet of things: A survey," *Comput. Netw.*, vol. 54, no. 15, pp. 2787–2805, Oct. 2010. [Online]. Available: <http://dx.doi.org/10.1016/j.comnet.2010.05.010>.
- Sadri, Fariba. "Ambient intelligence: A survey." *ACM Computing Surveys (CSUR)* 43.4 (2011): 36.
- S. Karpischek, F. Michahelles, F. Resatsch, E. Fleisch, Mobile sales assistant – an NFC-based product information system for retailers, in: *Proceedings of the First International Workshop on Near Field Communications 2009*, Hagenberg, Austria, February 2009.
- A.M. Vilamovska, E. Hattziandreu, R. Schindler, C. Van Oranje, H. De Vries, J. Krapelse, *RFID Application in Healthcare – Scoping and Identifying Areas for RFID Deployment in Healthcare Delivery*, RAND Europe, February 2009.
- C. Buckl, S. Sommer, A. Scholz, A. Knoll, A. Kemper, J. Heuer, A. Schmitt, Services to the field: an approach for resource constrained sensor/actor networks, in: *Proceedings of WAINA'09*, Bradford, United Kingdom, May 2009.
- E. Welbourne, L. Battle, G. Cole, K. Gould, K. Rector, S. Raymer, M. Balazinska, G. Borriello, Building the internet of things using RFID: the RFID ecosystem experience, *IEEE Internet Computing* 13 (3) (2009) 48–55.
- Khan, I., Mahmood, A., Javaid, N., Razzaq, S., Khan, R. D., & Ilahi, M. (2013). Home energy management systems in future smart grids. arXiv preprint arXiv:1306.1137.

- A. Kailas, V. Cecchi, and A. Mukherjee, "A survey of communications and networking technologies for energy management in buildings and home automation," *Journal of Computer Networks and Communications*, vol. 2012, 2012.
- U. Maurer, a. Smailagic, D. P. Siewiorek, and M. Deisher, "Activity Recognition and Monitoring Using Multiple Sensors on Different Body Positions," *Int. Work. Wearable Implant. Body Sens. Networks*, pp. 113–116, 2006.
- Osmani, Venet, Sasitharan Balasubramaniam, and Dmitri Botvich. "Human activity recognition in pervasive health-care: Supporting efficient remote collaboration." *Journal of network and computer applications* 31.4 (2008): 628-655.
- Nguyen, Tuan Anh, and Marco Aiello. "Energy intelligent buildings based on user activity: A survey." *Energy and buildings* 56 (2013): 244-257.
- B. Dong, B. Andrew, Sensor-based occupancy behavioral pattern recognition for energy and comfort management in intelligent buildings, in: *Proceedings of Building Simulation 2009*, an IBPSA Conference, Glasgow, U.K, 2009.
- K. Padmanabh, A. Malikarjuna, V.S. Sen, S.P. Katru, A. Kumar, S.P.C.S.K. Vuppala, S. Paul, iSense: a wireless sensor network based conference room management system, in: *Proceedings of the First ACM Workshop on Embedded Sensing Systems for Energy-Efficiency in Buildings, BuildSys '09*, ACM, New York, NY, USA, 2009, pp. 37–42.
- A. Marchiori, Q. Han, Distributed wireless control for building energy management, in: *Proceedings of the 2nd ACM Workshop on Embedded Sensing Systems for Energy-Efficiency in Building, BuildSys '10*, ACM, New York, NY, USA, 2010, pp. 37–42.
- G. Meditskos, S. Dasiopoulou, V. Efstathiou, and I. Kompatsiaris, "SP-ACT: A Hybrid Framework for Complex Activity Recognition Combining OWL and SPARQL Rules," *10th IEEE Work. Context Model. Reason.*, no. March, pp. 25–30, 2013.
- Witten, Ian H., and Eibe Frank. *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2005.
- S. Tompros, N. Mouratidis, M. Draaijer, A. Foglar, and H. Hrasnica, "Enabling applicability of energy saving applications on the appliances of the home environment," *IEEE Netw.*, vol. 23, pp. 8–16, 2009.
- Model, Business Process. "Notation (BPMN) Version 2.0." *OMG Specification*, Object Management Group (2011).

Kohavi, Ron (1995). "A study of cross-validation and bootstrap for accuracy estimation and model selection". Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence (San Mateo, CA: Morgan Kaufmann) 2 (12): 1137–1143.