



Trabalho de Conclusão de Curso

Desagregação de Energia Utilizando GSP

Bruno Marques Barbosa
brunomb@ic.ufal.br

Orientador:
Prof. Dr. André Luiz Lins de Aquino

Maceió, 27 de Março de 2020

Bruno Marques Barbosa

Desagregação de Energia Utilizando GSP

Monografia apresentada como requisito parcial para obtenção do grau de Bacharel em Engenharia de Computação do Instituto de Computação da Universidade Federal de Alagoas.

Orientador:

Prof. Dr. André Luiz Lins de Aquino

Maceió, 27 de Março de 2020

Monografia apresentada como requisito parcial para obtenção do grau de Bacharel em Engenharia de Computação do Instituto de Computação da Universidade Federal de Alagoas, aprovada pela comissão examinadora que abaixo assina.

Prof. Dr. André Luiz Lins de Aquino - Orientador
Instituto de Computação
Universidade Federal de Alagoas

Prof. Dr. Leonardo Viana Pereira - Examinador
Instituto de Computação
Universidade Federal de Alagoas

Randy Ambrósio Quindai João - Examinador
Instituto de Computação
Universidade Federal de Alagoas

Agradecimentos

Agradeço à minha família, meu pai Petrócio, minha mãe Maria e meu irmão Pedro, pelo apoio incondicional; não esquecendo, também, os demais familiares por nunca duvidarem que eu chegaria até aqui.

Agradeço à todos os colegas do Laboratório de Computação Científica e Análise Numérica (LaCCAN) e Laboratório de Computação Científica e Visualização (LCCV), tanto os bolsistas quanto os orientadores, por terem ajudado e contribuído em todos os projetos nos quais estive envolvido nos laboratórios citados.

Agradeço aos professores do Instituto de Computação, por terem contribuído para minha formação como engenheiro de computação.

Agradeço à todos os amigos que fiz durante essa jornada estudantil (quando eu falo isso é desde a escola), por mostrarem à mim que um bom relacionamento entre os colegas dentro e fora da universidade (ou ambiente de trabalho) nos ensina a respeitar as diferenças e desenvolver um bom ambiente de trabalho, que nos motiva cada vez mais a fazer um bom trabalho e ganhar gosto pelo que estamos fazendo.

Agradeço à Deus, por ter me dado a vida, por colocar todas essas pessoas na minha vida, por permitir que eu chegasse até aqui, e por não ter me dado prova maior do que aquela que eu possa suportar (1 Coríntios 10:13).

Resumo

O uso de dispositivos computacionais acabou gerando, com o passar do tempo, um grande acúmulo de dados. Esses dados vão desde recibos de compras a processos judiciais. Sendo assim, há um grande interesse comercial e acadêmico em saber o que fazer com tais dados, de forma a extrair informação importante deles.

Trabalhos relacionados ao problema da desagregação de energia e do monitoramento não-intrusivo de cargas envolvem criação de conjuntos de dados para o estudo do problema, criação de dispositivos para a coleta de dados, entre outros.

O problema da desagregação de energia consiste em coletar dados dos quadros gerais das casas, que é onde a energia elétrica vinda dos postes é distribuída para a casa, e dos eletrodomésticos individualmente e, utilizando algoritmos, obter dados que se aproximam muito dos dados coletados dos eletrodomésticos, ou seja, dados os dados de energia de uma casa, verificar quais eletrodomésticos estão utilizando aquelas cargas em determinada hora do dia. Este problema faz parte do NILM (*Non-intrusive Load Monitoring*), que é um conjunto de técnicas, que envolvem hardware e software, para monitoramento de energia elétrica, a fim de que a energia possa ser melhor utilizada pelos moradores.

A solução utilizada envolve um algoritmo chamado GSP (*Graph Signal Monitoring*), que utiliza processamento de sinais para a construção de grafos com dados de sinais (no caso da desagregação de energia, os sinais são a energia elétrica) e, a partir desses grafos, verificar quais dados são mais similares e, assim, agrupá-los para formar os eletrodomésticos que consumiram a energia elétrica da casa. Este método é uma forma de se desagregar energia sem utilizar treinamento, como os métodos que usam *Deep Learning*, por exemplo.

A aplicação do algoritmo utilizou bases de dados públicas, como o REDD (*Reference Energy Disaggregation Dataset*) e o REFIT, a fim de implementar as soluções apresentadas pelo artigo que publicou o algoritmo baseado em GSP. A desagregação foi realizada, os dados desagregados obtidos se aproximam dos resultados coletados individualmente, porém, é necessário melhorar a acurácia.

Palavras-chave: Desagregação de energia, GSP, Python.

Abstract

The use of computational devices eventually generated a large accumulation of data. This data ranges from purchase receipts to lawsuits. Therefore, there is a strong business and academic interest in what to do with such data in order to extract important information from them.

Work related to the problem of energy disaggregation and non-intrusive load monitoring involves creating data sets to study the problem, creating devices for data collection, among others.

The problem of power disaggregation is to collect data from the house overviews, which is where the electric power coming from the poles is distributed to the house, and from the individual appliances and, using algorithms, to get data that comes very close to the data collected from the appliances, ie given the energy data of a home, check which appliances are using those loads at a particular time of day. This problem is part of Non-intrusive Load Monitoring (NILM), which is a set of techniques that involve hardware and software for monitoring power so that energy can be better utilized by residents.

The solution used involves an algorithm called GSP (Graph Signal Monitoring), which uses signal processing to construct graphs with signal data (in the case of energy breakdown, the signals are electrical energy) and from these graphs, check which data are most similar and thus group them together to form the appliances that have consumed the electricity of the house. This method is a way of disaggregating energy without training, such as Deep Learning methods, for example.

The application of the algorithm used public databases, such as REDD (Reference Energy Disaggregation Dataset) and REFIT, in order to implement the solutions presented by the article that published the GSP-based algorithm. The disaggregation was performed, the disaggregated data obtained approximate the results collected individually, but it is necessary to improve the accuracy.

Keywords: Energy Disaggregation, GSP, Python.

Sumário

Lista de Figuras	vi
Lista de Tabelas	vii
1 Introdução	1
1.1 Definição do problema	1
1.2 Objetivo	2
1.3 Trabalhos Relacionados	3
1.3.1 Desagregação de energia	3
1.3.2 GSP	4
1.4 Justificativa	5
1.5 Metodologia	7
1.6 Contribuições	9
1.7 Estrutura do texto	10
2 Monitoramento não-intrusivo de cargas de dispositivos - NALM	11
2.1 O problema da desagregação de energia	15
2.2 Algoritmos NILM de última geração	18
3 Graph Signal Processing para desagregação de energia	21
3.1 <i>Datasets</i>	23
3.1.1 Conjunto de dados (<i>Dataset</i>) REDD	23
3.1.2 Conjunto de dados (<i>Dataset</i>) REFIT	26
4 Resultados e Discussões	27
4.1 Resultados e Discussões	28
4.1.1 Pré-processamento	28
4.1.2 A desagregação	29
4.1.3 Avaliações	39
5 Considerações Finais	51
Referências bibliográficas	53

Lista de Figuras

1.1	Ilustração do Precision e do Recall.	8
1.2	<i>Performance</i> do algoritmo na casa 1 do REDD.	9
1.3	<i>Performance</i> do algoritmo na casa 2 do REDD.	9
1.4	<i>Performance</i> do algoritmo na casa 6 do REDD.	10
1.5	<i>Performance</i> do algoritmo na casa 8 do REFIT.	10
2.1	Monitor de carga do aparelho não invasivo montado no colar.	12
2.2	Potência versus tempo (carga total) mostra alterações de etapas devido a eventos individuais do dispositivo.	13
2.3	Diagrama esquemático das bordas.	17
2.4	Diagrama esquemático do FHMM.	19
3.1	Fluxograma do algoritmo proposto em Zhao et al. (2016)	24
3.2	Fluxograma do algoritmo proposto em Zhao et al. (2015)	25
3.3	Esquemático que mostra o processo de coleta dos dados do REDD.	26
4.1	Comparação da desagregação feita com os dados da primeira <i>main</i> da casa 1 do REDD com os dados desagregados da mesma casa.	32
4.2	Comparação da desagregação feita com os dados da segunda <i>main</i> da casa 1 do REDD com os dados desagregados da mesma casa.	32
4.3	Comparação da desagregação feita com os dados da primeira <i>main</i> da casa 2 do REDD com os dados desagregados da mesma casa.	33
4.4	Comparação da desagregação feita com os dados da segunda <i>main</i> da casa 2 do REDD com os dados desagregados da mesma casa.	33
4.5	Comparação da desagregação feita com os dados da primeira <i>main</i> da casa 6 do REDD com os dados desagregados da mesma casa.	34
4.6	Comparação da desagregação feita com os dados da segunda <i>main</i> da casa 6 do REDD com os dados desagregados da mesma casa.	34
4.7	Comparação da desagregação feita com os dados da casa 8 do REFIT com os dados desagregados da mesma casa.	35
4.8	Comparação da desagregação feita com os dados da primeira <i>main</i> da casa 1 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.	38
4.9	Comparação da desagregação feita com os dados da segunda <i>main</i> da casa 1 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.	39
4.10	Comparação da desagregação feita com os dados da primeira <i>main</i> da casa 2 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.	40

4.11 Comparação da desagregação feita com os dados da segunda <i>main</i> da casa 2 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.	41
4.12 Comparação da desagregação feita com os dados da primeira <i>main</i> da casa 6 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.	42
4.13 Comparação da desagregação feita com os dados da segunda <i>main</i> da casa 6 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.	42
4.14 Comparação da desagregação feita com os dados da casa 8 do REFIT com os dados desagregados da mesma casa após a mudança nos parâmetros.	43
4.15 Comparação da desagregação feita com os dados de demonstração utilizados na implementação do algoritmo.	43

Lista de Tabelas

4.1	Avaliação dos dados de demonstração.	41
4.2	Avaliação dos dados da primeira <i>main</i> da casa 1 do REDD, com os parâmetros do artigo.	44
4.3	Avaliação dos dados da segunda <i>main</i> da casa 1 do REDD, com os parâmetros do artigo.	44
4.4	Avaliação dos dados da primeira <i>main</i> da casa 2 do REDD, com os parâmetros do artigo.	45
4.5	Avaliação dos dados da segunda <i>main</i> da casa 2 do REDD, com os parâmetros do artigo.	45
4.6	Avaliação dos dados da primeira <i>main</i> da casa 6 do REDD, com os parâmetros do artigo.	46
4.7	Avaliação dos dados da segunda <i>main</i> da casa 6 do REDD, com os parâmetros do artigo.	46
4.8	Avaliação dos dados da casa 8 do REFIT, com os parâmetros do artigo.	46
4.9	Avaliação dos dados da primeira <i>main</i> da casa 1 do REDD, com os parâmetros modificados.	47
4.10	Avaliação dos dados da segunda <i>main</i> da casa 1 do REDD, com os parâmetros modificados.	47
4.11	Avaliação dos dados da primeira <i>main</i> da casa 2 do REDD, com os parâmetros modificados.	47
4.12	Avaliação dos dados da segunda <i>main</i> da casa 2 do REDD, com os parâmetros modificados.	48
4.13	Avaliação dos dados da primeira <i>main</i> da casa 6 do REDD, com os parâmetros modificados.	48
4.14	Avaliação dos dados da segunda <i>main</i> da casa 6 do REDD, com os parâmetros modificados.	48
4.15	Avaliação dos dados da casa 8 do REFIT, com os parâmetros modificados.	49

1

Introdução

O uso de dispositivos computacionais acabou gerando, com o passar do tempo, um grande acúmulo de dados. Esses dados vão desde recibos de compras a processos judiciais. Sendo assim, há um grande interesse comercial e acadêmico em saber o que fazer com tais dados, de forma a extrair informação importante deles.

Uma aplicação dessa ciência de dados encontra-se na área da engenharia elétrica, que é a desagregação de energia. Consiste em coletar dados de potência do quadro geral da casa e as cargas individuais (coleta dos dados de potência dos eletrodomésticos) e utilizando algoritmos, separar a potência dos eletrodomésticos da casa dos dados do quadro geral e compará-los com os dados do quadro geral. Tudo isso envolve o contexto do NILM (*Non-intrusive Appliance Load Monitoring*), monitoramento não-intrusivo das cargas elétricas dos eletrodomésticos.

O algoritmo utilizado neste trabalho envolve GSP (*Graph Signal Processing*), que transforma os dados de potência em vértices de um grafo e a matriz de adjacência é calculada a partir de um kernel gaussiano. O grafo de sinal é então gerado fazendo um mapeamento dos vértices desse grafo com números complexos. A partir daí, os dados são organizados em conjuntos de acordo com as suas semelhanças, rotulados ao serem comparados com um banco de dados específico para fazer a rotulação e tem-se o resultado final, com a desagregação. Este tipo de algoritmo é uma forma de se obter a desagregação sem nenhuma forma de treinamento, como o algoritmo FHMM, por exemplo.

1.1 Definição do problema

O problema consiste em: dado um conjunto de dados de potência ativa, coletados de uma residência qualquer, verificar quais eletrodomésticos estão utilizando determinada parte de potência, com um método que utiliza processamento de sinais.

1.2 Objetivo

O objetivo é executar um algoritmo de NILM que não requeira treinamento, observando seu desempenho em alguns conjuntos de dados públicos.

1.3 Trabalhos Relacionados

Abaixo são citados vários trabalhos relacionados ao problema da desagregação de energia, do monitoramento não-intrusivo de cargas e de GSP.

1.3.1 Desagregação de energia

O início da teoria de desagregação de energia se dá a partir de [Hart \(1992\)](#). Ele define o monitoramento não intrusivo de cargas elétricas como "o consumo de energia de dispositivos individuais ligando e desligando em uma carga elétrica, com base em análises detalhadas da corrente e tensão da carga total, conforme medido na interface da fonte de energia". [Hart \(1992\)](#) também diz que o método "é chamado de não intrusivo por contrastar com as técnicas anteriores de coleta de dados de carga de equipamentos, que exigem a colocação de sensores em aparelhos individuais e, portanto, uma intrusão nas propriedades do consumidor de energia".

[Kolter and Johnson \(2011\)](#) propõe um conjunto de dados público, utilizado para a realização de estudos de caso, chamado REDD (*Reference Energy Disaggregation Dataset*), de dados de potência coletados de 6 casas nos Estados Unidos, a cada 1 segundo, durante 1 mês.

[Batra et al. \(2014\)](#) apresenta um conjunto de ferramentas, o NILMTK, para a utilização de conjuntos de dados públicos, onde é possível fazer a análise dos dados e a aplicação de algoritmos de desagregação, como o FHMM (*Factorial Hidden Markov Model*) e o Combinatorial Optimisation, bem como a avaliação de seus desempenhos, a partir de métricas como o F1 score.

[Faustine et al. \(2017\)](#) apresenta uma coletânea de algoritmos utilizados para a desagregação de energia e métodos de monitoramento não-intrusivo de cargas.

[Quindai et al. \(2017\)](#) apresenta um dispositivo de baixo custo para a coleta de dados de potência em eletrodomésticos baseado em *Arduino*, bem como uma nova base de dados, cujos dados foram coletados a partir deste dispositivo.

[Liao et al. \(2014\)](#) apresenta um algoritmo baseado em Árvore de Decisão, supervisionado, para fazer treinamento e teste dos dados de potência ativa, e um não supervisionado, o *Dynamic Time Warping*, utilizado para classificação e combinação de padrões. O foco, neste trabalho, são as amostras de baixas taxas de tempo (6 segundos e 1 minuto).

Em [Kelly and Knottenbelt \(2015\)](#) os autores utilizam o *Deep Learning* para a desagregação de energia. Três redes neurais profundas são utilizadas neste trabalho: uma forma de rede neural recorrente (*Recurrent Neural Network - RNN*) chamada *'long short-term memory (LSTM)*; *Autoencoders* eliminadores de ruído e uma rede que regride a hora de início, hora de término e demanda média de energia de cada ativação do dispositivo e utilizam sete métricas para a avaliação dos algoritmos, entre elas, como neste trabalho, o F1.

[Kim et al. \(2011\)](#) investiga a eficácia de vários métodos de desagregação não supervisionados em medições de potência de baixa frequência coletadas em residências reais, especifica-

mente, as variantes do *Factorial Hidden Markov Model*.

[Altrabalsi et al. \(2016\)](#) desenvolve uma abordagem alternativa baseada na máquina de vetores de suporte (SVM) e *k-means*, em que o *k-means* é usado para reduzir o tamanho do conjunto de treinamento SVM, identificando apenas o subconjunto representativo do conjunto de dados original para o treinamento SVM. Tal abordagem é utilizada visando minimizar o alto custo computacional proporcionado pelo *Factorial Hidden Markov Model*.

[Wild et al. \(2015\)](#) apresenta um detector de eventos NILM não supervisionado com base na análise discriminante de Fisher do kernel (KFDA), que fornece horários de início e término precisos das chamadas seções ativas, devido ao fato de enfrentando os sistemas NILM enfrentarem cada vez mais cargas não lineares e variáveis.

1.3.2 GSP

[Zhao et al. \(2016\)](#) utiliza GSP para criar um algoritmo "cego", que não exige treinamento, para a realização da desagregação de energia.

[Zhao et al. \(2015\)](#) apresenta o estado-da-arte para o problema abordado por [Zhao et al. \(2016\)](#), que foi complementado por este.

[Sandryhaila and Moura \(2013b\)](#) dispõe sobre a teoria de grafo de processamento de sinais discretos (DSP - *Discrete Signal Processing*), uma variação do GSP, para sinais discretos, relacionando a teoria de processamento digital de sinais, incluindo Transformada Z, Convolução, Filtros, Transformada de Fourier Discreta, entre outros, com a teoria dos grafos.

[Sandryhaila and Moura \(2014\)](#) discute um paradigma para análise de dados em larga escala com base no processamento de sinal discreto (DSP) em grafos (DSPG), que estende o processamento de sinais aos grafos com o intuito de processar grandes volumes de dados. Isso inclui, também, a teoria contida em [Sandryhaila and Moura \(2013b\)](#).

[Stankovic et al. \(2014\)](#), anterior à [Zhao et al. \(2016\)](#), propôs uma abordagem NALM representando o conjunto de dados de assinaturas de energia ativa usando um grafo de sinal. Porém, seu algoritmo é mais simples que o algoritmo proposto por [Zhao et al. \(2016\)](#), e realiza treinamento e teste, o que é o contrário do proposto por [Zhao et al. \(2016\)](#).

[Sandryhaila and Moura \(2013a\)](#) apresenta a teoria de classificação baseada em grafos de sinais. "Nossa abordagem é baseada na teoria do processamento discreto de sinais em gráficos, onde o gráfico representa semelhanças entre os dados e interpretamos os rótulos para os elementos do conjunto de dados como um sinal indexado pelos nós do gráfico" ([Sandryhaila and Moura, 2013a](#)).

[He et al. \(2016\)](#) utiliza duas abordagens para o NILM baseado em GSP, "a primeira abordagem, baseada na minimização total da variação do grafo, procura um grafo de sinal suave sob restrições conhecidas de rotulagem. A segunda abordagem usa o minimizador de variação total do grafo como ponto de partida para refinamentos adicionais via têmpera simulado". O objetivo é abordar a sobrecarga de treinamento e complexidade em métodos tradicionais baseados em

grafos, porém, com uma abordagem baseada em eventos.

[Shuman et al. \(2013\)](#) discute sobre as áreas que utilizam a teoria do GSP, bem como apresentar os maiores desafios da área, e apresenta tutoriais de como realizar coisas específicas da área, como definir domínios espectrais de grafos, discorre sobre a importância de incorporar as estruturas irregulares dos domínios de dados de gráficos ao processar sinais em grafos, revisa teorias sobre a área do processamento de sinais e apresenta demandas futuras da área.

1.4 Justificativa

[Zhao et al. \(2016\)](#) classifica os métodos de NILM em 3 grupos.

O Grupo 1 compreende todas as abordagens tradicionais não supervisionadas, que exigem dados de treinamento não rotulados para criar modelos de dispositivos ou preencher banco de dados de dispositivos. Baseia-se em clusterização hierárquica, ou HMMs (*Hidden Markov Models*).

O Grupo 2 consiste em métodos NALM que usam 'casas conhecidas' para a construção de modelos de eletrodomésticos, que são então usados para desagregação em casas 'desconhecidas' (invisíveis). Estes incluem algoritmos de clusterização como o *k-means* e o *Deep Learning*.

Métodos que não requerem treinamento antes da desagregação estão no Grupo 3. Estes incluem, por exemplo, o *Kernel Fisher Discriminant Analysis* (KFDA). No entanto, exige altas taxas de amostragem e usa harmônicos de corrente.

O método proposto por [Zhao et al. \(2016\)](#) difere dos do Grupo 1 por não requerer treinamento e difere dos do Grupo 2 por não necessitar de sub-medidas. Ele é mais próximo dos do Grupo 3 por não requerer nenhum treinamento, devido à ser baseado em processamento de sinais, e tem a vantagem de ter uma baixa complexidade.

Em relação à aplicação, [Hart \(1992\)](#) fala que a principal aplicação que impulsionou essa pesquisa é o monitoramento de pesquisas de carga. As grandes empresas de energia elétrica geralmente monitoram dezenas a centenas de seus clientes residenciais com monitores de carga intrusivos colocados em duas a oito cargas principais, como calor elétrico, aquecedores de água, geladeiras e ar condicionado. Esses dados são estatisticamente calculados pela média dentro das classes demográficas e usados para diversos propósitos por muitos públicos, incluindo analistas de carga, analistas de taxas, formuladores de políticas públicas e projetistas de eletrodomésticos. As técnicas NALM são especialmente úteis para o monitoramento utilitário de cargas residenciais. A facilidade de instalação permitirá que mais dispositivos sejam monitorados em mais residências, fornecendo dados mais amplos e, em muitos casos, dados mais precisos do que era possível com a tecnologia atual. Custo mais baixo, resolução mais fina e facilidade de instalação, remoção e manutenção (sem a necessidade de uma consulta com os residentes para obter entrada) são recursos muito valiosos da perspectiva da concessionária.

Uma aplicação relacionada é o monitoramento de clientes individuais de serviços públicos com o objetivo de uma "auditoria energética". Um NALM pode ser instalado temporariamente a pedido do cliente, a fim de analisar as características dos dispositivos. Depois de uma semana a um mês, produziria um relatório detalhado de consumo de energia que seria útil para sugerir maneiras de reduzir o consumo e os custos. O relatório pode estar na forma de uma conta de serviço público "desagregada", que se parece muito mais com uma conta de telefone, na medida em que relaciona as cobranças. Uma segunda auditoria é frequentemente valiosa para confirmar as economias resultantes de medidas de conservação. Outro uso é o monitoramento de energia para fins de análise de falhas ou segurança. Os aparelhos com falha geralmente podem ser detectados por seu consumo incomum de energia ou ciclos de serviço. Como sub-produto de um teste de campo, uma bomba séptica subterrânea com falha foi detectada pelo seu consumo de energia anormalmente baixo. Em outro teste de campo, um refrigerador que estava quase o tempo todo foi detectado e substituído. "Automação residencial" é uma área de aplicação intimamente relacionada.

Como exemplo de segurança, uma casa de férias desocupada por longos períodos pode ser monitorada em um único ponto, e ainda verificar muitas funções. O monitor pode ser programado para gerar automaticamente uma mensagem telefônica para relatar o uso do dispositivo acima ou abaixo dos limites especificados. Se a geladeira falhar, se uma luz de segurança se acender, se os abridores das portas da garagem estiverem ativados, se a bomba de água estiver ligada excessivamente (talvez indicando um cano estourado) etc., o proprietário será notificado imediatamente. Infelizmente, esses aplicativos também sugerem problemas de privacidade e aplicativos de vigilância nos quais o NALM pode ser abusado.

Outra aplicação envolve a verificação do controle de gerenciamento de carga do lado da demanda. Muitas concessionárias de energia elétrica instalam controladores de eletrodomésticos em cargas diferidas em toda a base de clientes, para eliminá-los durante os períodos de pico de uso de energia. Um NALM pode verificar se o sistema está de fato operacional e não foi derrotado por interferências de rádio ou cliente. Ele também pode ser incorporado às formas de "intertravamento do dispositivo" de estratégias de controle de carga. Por exemplo, um controlador de carga pode ser projetado para operar uma carga adiada como uma função do estado *ON / OFF* de outras cargas não adiadas. O NALM pode determinar o estado das cargas não diferíveis de um único sensor sem a necessidade de executar a fiação do sensor a partir delas.

As aplicações acima podem ser residenciais, comerciais ou industriais - três classes de clientes de serviços públicos que são tratados apenas de maneira ligeiramente diferente, devido aos diferentes tipos de cargas que eles contêm. Até agora, as implementações e os testes de campo foram focados em cargas residenciais porque a intrusão é mais um problema, mas com alguma consideração sobre cargas comerciais.

Existe uma classe final de aplicativos em que o NALM pode ser uma ferramenta extremamente valiosa, mas que ainda não exploramos seriamente: situações em que não é possível obter acesso físico a cargas individuais, portanto não há como monitorá-las com sensores indi-

viduais. Os exemplos podem incluir circuitos inacessíveis em um chip VLSI ou devido a locais submarinos ou extraterrestres.

1.5 Metodologia

A implementação do algoritmo de desagregação proposto por [Zhao et al. \(2016\)](#) e reproduzido neste trabalho foi implementado na linguagem Python, utilizando módulos utilizados em análise de dados, como o *NumPy* e o *Pandas*, porém, em certo momento, a linguagem R foi utilizada para o pré-processamento, sobretudo na conversão de timestamp para formato de data e hora. As bases de dados utilizadas foram o REFIT, que coleta dados de potência a cada 8 segundos em residências do Reino Unido, e o REDD, que coleta dados de potência de residências americanas a cada 1 segundo.

[Zhao et al. \(2016\)](#) fala das métricas de avaliação deste algoritmo. Ele utiliza as métricas *Precision* (PR - dos que foram classificados como positivo, quais eram mesmo positivos), *Recall* (RE - dos que são realmente positivos quais foram classificados como positivos) e *F-measure* (F_M - dobro da média harmônica entre o Precision e o Recall). As fórmulas são:

$$PR = \frac{TP}{TP + FP}$$

$$RE = \frac{TP}{TP + FN}$$

$$F_M = \frac{2}{\frac{1}{PR} + \frac{1}{RE}} = 2 * \frac{PR * RE}{PR + RE}$$

, onde TP é *True Positive* (Verdadeiro Positivo), FP é *False Positive* (Falso Positivo) e FN é *False Negative* (Falso Negativo). Abaixo, a Figura 1.1, retirada de [Wikipedia](#), ilustra essas métricas. Entretanto, neste trabalho, o Verdadeiro Positivo foi separado em dois, o ATP (*Accurate True Positive* - declaração correta de que o dispositivo detectado estava em execução e os eventos correspondentes foram nomeados corretamente) e o ITP (*Inaccurate True Positive* - declaração correta de que o dispositivo detectado estava em execução, mas os eventos correspondentes foram nomeados incorretamente). As fórmulas de *Precision* e *Recall*, então, sofrem uma modificação:

$$PR = \frac{ATP}{ATP + FP}$$

$$RE = \frac{ATP}{ATP + ITP + FN}$$

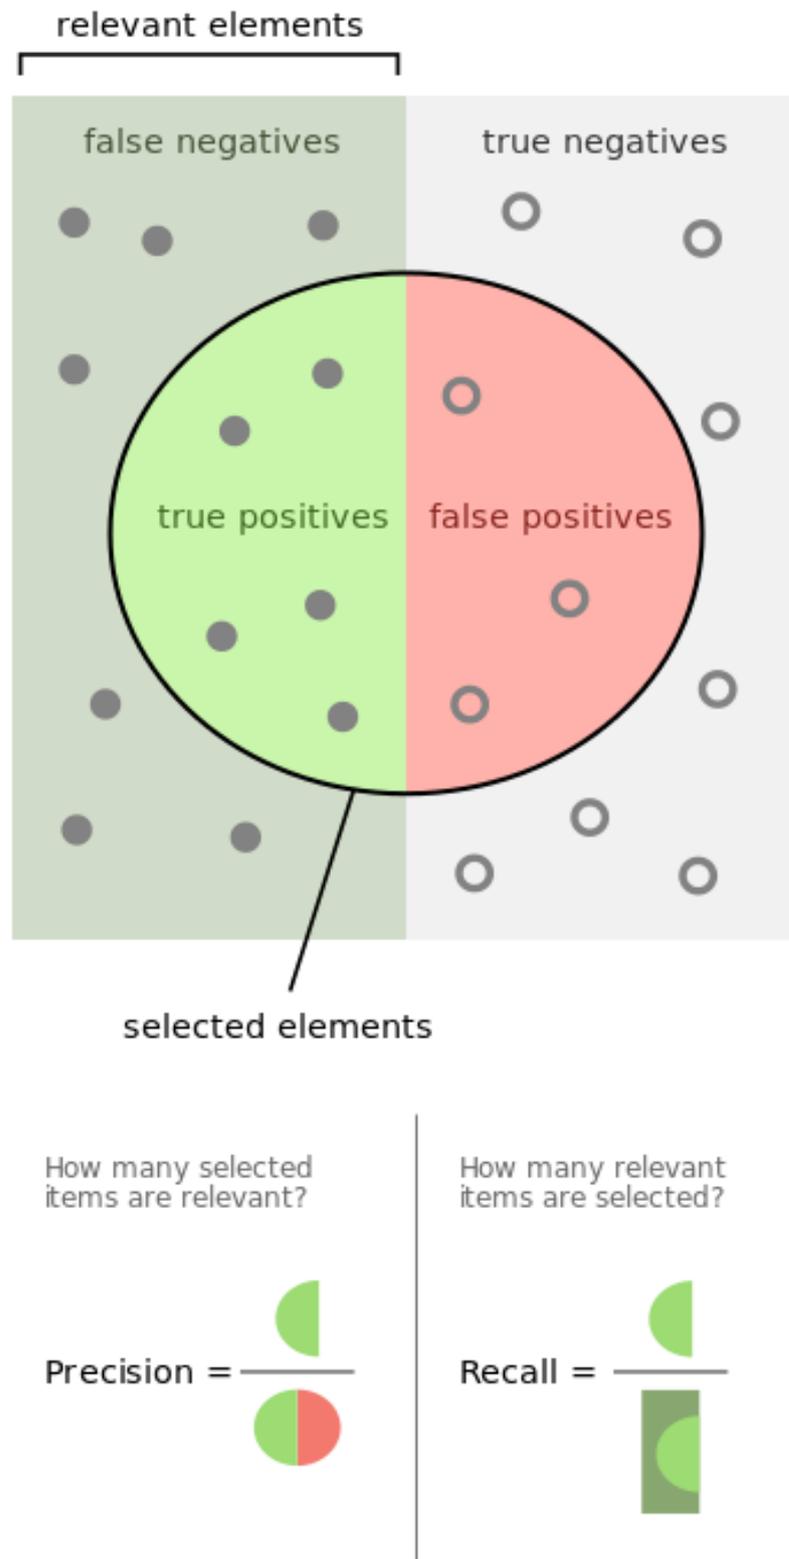


Figura 1.1: Ilustração do Precision e do Recall.

Zhao et al. (2016) mediu a *performance* do algoritmo, e são mostradas abaixo, nas Figuras 1.2, 1.3, 1.4 e 1.5. Na Figura 1.2, o F_M deu um valor baixo para *dishwasher*, devido à sua

similaridade com *refrigerator*. A média de potência do *refrigerator* é de 201 W, enquanto que a da *dishwasher* é de 210,6 W, o que é explicado pelo alto valor de ITP, de *dishwasher*, classificado erroneamente como *refrigerator*. As Figuras 1.3 e 1.4 mostram valores de F_M maiores que 70%, o pior valor, na casa 2, foi o de *stove*, devido ao alto valor de FP. Na casa 6, *heater* e *lighting* tiveram as piores performances, devido às medições realizadas diretamente nas residências (chamadas de *Ground Truth*) cheias de ruídos, portanto, medições questionáveis. Na casa 8 do REFIT, mostrada na Figura 1.5, houve bons resultados para *refrigerator* e *kettle*, mas péssimos para *television*, devido à *television* e *freezer* terem suas potências ativas em valores muito próximos. A média de F_M de todas as aplicações foi de $F_M = 0,49$, enquanto que, para algoritmos baseados em HMM, a performance foi de $F_M = 0,46$.

Como a implementação do algoritmo foi feita em *Python*, foi utilizado um módulo na mesma linguagem para os cálculos mencionados no parágrafo anterior, que foi o *pandas_ml*. Tal módulo possui uma função chamada *confusion_matrix*, que mostra as estatísticas completas do resultado da desagregação, em relação ao resultado esperado.

Appliance	ATP	ITP	FP	FN	PR	RE	F_M
Microwave	174	105	21	13	0.89	0.6	0.72
Kitchen outlet	19	14	1	13	0.95	0.41	0.57
Washer dryer	191	31	11	78	0.95	0.64	0.76
Oven	29	4	2	26	0.94	0.49	0.64
Lighting	35	26	16	32	0.69	0.38	0.49
Refrigerator	513	50	20	127	0.96	0.74	0.84
Dishwasher	49	139	3	15	0.94	0.24	0.38
Bathroom GFI	39	11	9	10	0.81	0.65	0.72

Figura 1.2: *Performance* do algoritmo na casa 1 do REDD.

Appliance	ATP	ITP	FP	FN	PR	RE	F_M
Microwave	80	5	0	5	1	0.89	0.94
Kitchen outlet1	39	0	1	13	0.98	0.75	0.85
Kitchen outlet2	172	9	11	18	0.94	0.86	0.85
Stove	34	0	83	4	0.29	0.89	0.44
Refrigerator	595	17	110	161	0.84	0.77	0.8
Dishwasher	19	15	11	13	0.63	0.4	0.49
Lighting	70	0	110	9	0.64	0.89	0.74

Figura 1.3: *Performance* do algoritmo na casa 2 do REDD.

1.6 Contribuições

Zhao et al. (2016) diz que, devido à sua baixa complexidade, operação simples e entrada mínima do cliente (para rotulagem inicial), o algoritmo proposto por ele pode ser aplicado em

Appliance	ATP	ITP	FP	FN	PR	RE	F_M
Microwave	10	0	3	0	0.77	1	0.87
Kitchen outlets	4	1	3	3	0.57	0.5	0.53
Stove	7	5	3	2	0.7	0.5	0.58
Refrigerator	439	8	56	132	0.89	0.76	0.82
Electronics	26	6	61	5	0.3	0.7	0.42
Heater	3	0	56	3	0.05	0.5	0.09
Air Conditioner	44	9	0	1	1	0.81	0.9
Lighting	7	6	7	12	0.5	0.28	0.36
Outlets unknown	146	6	56	65	0.72	0.67	0.69

Figura 1.4: *Performance* do algoritmo na casa 6 do REDD.

Appliance	ATP	ITP	FP	FN	PR	RE	F_M
Microwave	7	10	0	3	1	0.35	0.52
Toaster	4	1	2	1	0.67	0.67	0.67
Kettle	39	7	6	2	0.87	0.81	0.84
Refrigerator	18	0	2	0	0.9	1	0.95
Freezer	54	16	180	24	0.23	0.57	0.32
TV	4	0	180	6	0.02	0.4	0.04
Washing Machine	3	1	8	0	0.27	0.75	0.4

Figura 1.5: *Performance* do algoritmo na casa 8 do REFIT.

larga escala como um sistema incorporado como parte do Consumer Access Device com uma interface de feedback on-line que os usuários podem acessar.

1.7 Estrutura do texto

A seção 2 apresenta uma motivação da utilização do NILM. A seção 3 apresenta uma proposta para a solução do problema da desagregação de energia. A seção 4 apresenta os resultados da solução proposta e a seção 5 as conclusões do trabalho e possíveis trabalhos futuros.

2

Monitoramento não-intrusivo de cargas de dispositivos - NALM

Segundo Hart (1992), um monitor de carga de dispositivo não invasivo (NALM) é projetado para monitorar um circuito elétrico que contém vários dispositivos que ligam e desligam independentemente. Por uma análise sofisticada das formas de onda de corrente e tensão da carga total, o NALM estima o número e a natureza das cargas individuais, seu consumo de energia individual e outras estatísticas relevantes, como variações da hora do dia. Não é necessário acesso aos componentes individuais para instalar sensores ou fazer medições. Isso pode fornecer um método muito conveniente e eficaz de coletar dados de carga em comparação com os meios tradicionais de colocar sensores em cada um dos componentes individuais da carga. Os dados de carga de uso final resultantes são extremamente valiosos para consumidores, serviços públicos, formuladores de políticas públicas e fabricantes de eletrodomésticos, para uma ampla variedade de propósitos.

Em um aplicativo utilitário, um NALM se conecta à carga total usando a interface padrão de soquete do medidor de receita, como mostra a Figura 2.1. Isso permite uma instalação, remoção e manutenção muito fáceis, em comparação com as técnicas tradicionais de monitoramento de carga intrusiva que requerem "submissão" e fiação interna. O NALM monitora a carga total, verificando certas "assinaturas" que fornecem informações sobre a atividade dos dispositivos que constituem a carga. Por exemplo, se a residência contiver um refrigerador que consome 250 W e 200 VAR, um aumento gradual desse tamanho de característica indica que o refrigerador foi ligado e uma diminuição desse tamanho indica os eventos de desligamento. Outros aparelhos possuem outras assinaturas características. Depois de determinar os horários exatos de ativação e desativação dos eventos de assinatura, todas as estatísticas desejadas, como consumo de energia versus hora do dia ou temperatura, podem ser tabuladas.

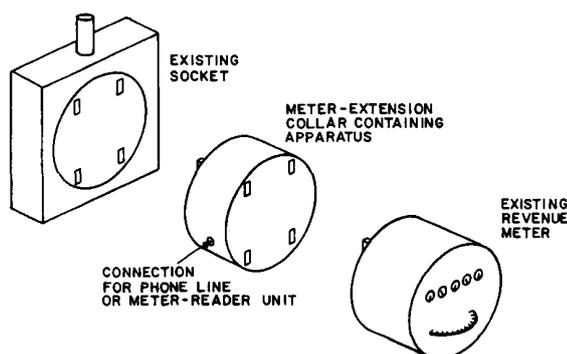


Figura 2.1: Monitor de carga do aparelho não invasivo montado no colar.

Para avaliar como isso funciona, considere a Figura 2.2, que mostra o consumo total de energia (real) versus o tempo de uma casa unifamiliar durante um período de quarenta minutos bastante movimentado. Durante esse intervalo, a carga total mostra uma grande quantidade de atividade, devido principalmente ao cozimento. Quatro mudanças de etapas de tamanhos diferentes estão claramente presentes, fornecendo assinaturas características do refrigerador, dois elementos do forno e um elemento do queimador do fogão. Considerando também as medições

da potência reativa total ou da corrente harmônica, juntamente com a potência real mostrada, as alterações na função vetorial resultante do tempo revelariam ainda mais informações sobre os aparelhos em particular.

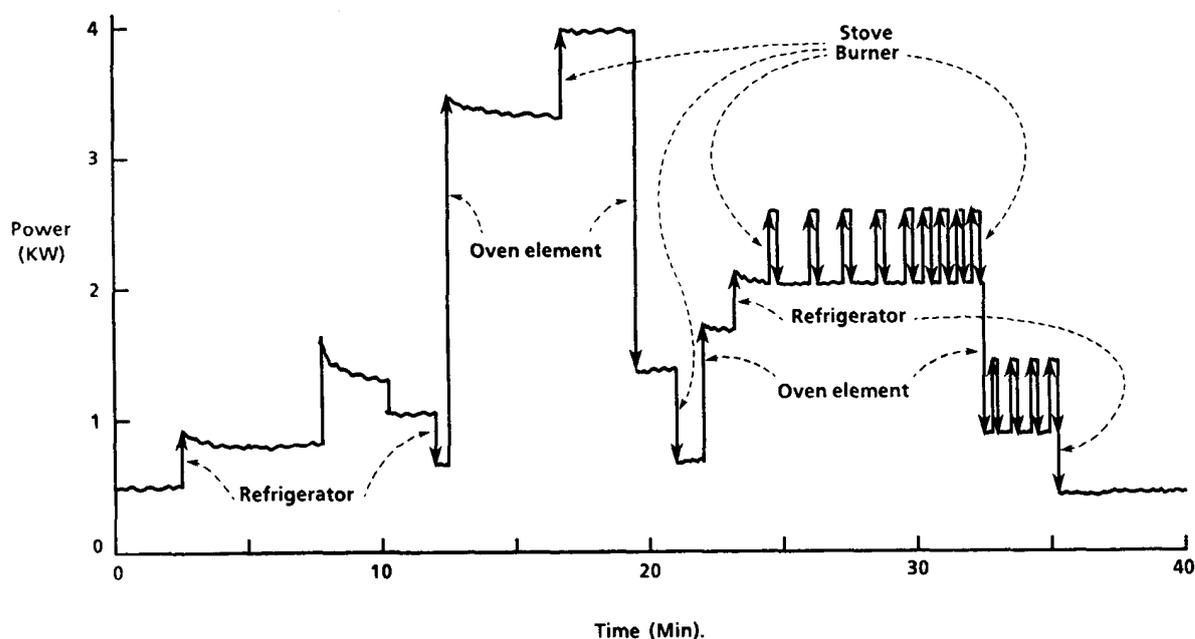


Figura 2.2: Potência versus tempo (carga total) mostra alterações de etapas devido a eventos individuais do dispositivo.

A instrumentação tradicional de pesquisa de carga envolve hardware complexo de coleta de dados, mas software simples. Um ponto de monitoramento em cada dispositivo de interesse e fios (ou às vezes técnicas de portadora de linha de força) que conectam cada um a um local central de coleta de dados fornece caminhos de dados separados, de modo que o software apenas precisa tabular os dados que chegam nesses canais de hardware separados. A abordagem NALM reverte esse equilíbrio, com hardware simples, mas software complexo para processamento e análise de sinal. Apenas um único ponto no circuito é instrumentado, mas os algoritmos matemáticos devem separar a carga medida em componentes separados. Em muitas aplicações de monitoramento de carga, esse é um compromisso muito econômico, que é uma grande vantagem do NALM. Equilibrando isso, há certas desvantagens, discutidas abaixo, que podem dominar em outros aplicativos.

Para decompor com precisão a carga agregada em seus componentes, é utilizada uma abordagem baseada em modelo para descrever dispositivos individuais e sua combinação. Esses modelos sugerem certas assinaturas que podem ser detectadas na carga total para indicar as atividades dos componentes separados. Isso leva naturalmente a arquiteturas e algoritmos práticos para o NALM.

Hart (1992) fala que existem dois objetivos NALM, de diferentes graus de não intrusividade. O segundo, menos intrusivo, é mais ambicioso tecnicamente, mas possui maiores vantagens:

(MS) “Configuração manual (*Manual setup*)”: um MS-NALM é um rastreador de comportamento não invasivo do dispositivo que requer um período intrusivo único para a instalação. Durante o período de instalação intrusiva, as assinaturas são observadas e nomeadas como os dispositivos são ativados e desativados manualmente. Distingue-se da instrumentação intrusiva convencional, pois nenhum hardware entra nas instalações sendo monitoradas.

(AS) “Configuração Automática” (*Automatic setup*): Um AS-NALM se auto-define conforme mede a carga, usando formação a priori sobre as características de possíveis aparelhos. Ele deve determinar as assinaturas importantes e os dispositivos aos quais eles estão associados, sem o benefício de qualquer pesquisa de entrada ou dispositivo.

O MS-NALM foi um trampolim no desenvolvimento do AS-NALM e provavelmente servirá como uma ferramenta de análise para situações em que o AS-NALM falhará, mas o AS-NALM acabará dominando a maioria das aplicações.

Com as alterações de energia usadas como assinaturas, conforme descrito na introdução, a configuração e operação do MS-NALM podem ser as descritas abaixo, com refinamentos a serem descritos abaixo. O AS-NALM distingue-se do MS-NALM pela eliminação das etapas (1) a (4). Em vez disso, ele cria sua própria tabela de assinaturas observando e analisando todas as alterações de etapa. Eles são nomeados com base em informações a priori programadas sobre quais tipos de dispositivos normalmente estão associados a quais tipos de assinaturas.

Resumo do procedimento de monitoramento com configuração manual (MS-NALM):

1. É feita uma pesquisa manual dos principais aparelhos.
2. O MS-NALM está instalado (Figura 2.1) e um teclado está temporariamente conectado a ele. Quando ativado, ele está no "modo de configuração", no qual são ensinadas as assinaturas apropriadas.
3. Cada dispositivo de interesse é ligado e desligado individualmente, e o nome do dispositivo é digitado no teclado. Quando isso acontece, o NALM monitora a energia e um detector de mudança de etapa determina o tamanho das assinaturas e as registra em uma tabela junto com o nome do dispositivo.
4. É dado um comando para colocar o NALM no "modo normal" e o teclado é desconectado.
5. O NALM opera de maneira não invasiva, medindo continuamente o nível de energia, verificando as alterações nas etapas e comparando-as com os tamanhos das assinaturas armazenadas. Sempre que uma alteração de etapa observada estiver próxima o suficiente de uma das assinaturas conhecidas, é sabido que o dispositivo foi ligado ou desligado, portanto, as estatísticas de energia apropriadas para esse dispositivo são atualizadas.

6. Em intervalos semanais, mensais ou outros, as estatísticas de energia coletadas são transferidas por telefone, leitor de medidor ou outro meio de comunicação para o centro de pesquisa de carga da concessionária.
7. Eventualmente, o NALM é removido, simplesmente desconectando-o do soquete e reinstalando o medidor de receita.

Por causa de sua total não intrusão, o AS-NALM é claramente superior do ponto de vista do usuário, se puder ser tão preciso quanto o MS-NALM. Os resultados dos testes de campo discutidos abaixo sugerem que o AS-NALM pode ser suficientemente preciso, mas testes mais amplos e uma implementação mais completa são necessários para confirmar isso. É possível encontrar certos casos difíceis que são melhor resolvidos com uma configuração manual. O MS-NALM também é o objetivo provável do primeiro esforço de comercialização atual, devido à sua relativa simplicidade e porque fornecerá informações para enriquecer o banco de dados do dispositivo necessário para o AS-NALM.

2.1 O problema da desagregação de energia

Segundo [Faustine et al. \(2017\)](#), a desagregação de energia é uma técnica que estima a energia consumida por cada aparelho individual em uma casa a partir de um único dispositivo de medição de energia, como um medidor inteligente. Essa técnica está ganhando popularidade devido às implantações de medidores inteligentes em larga escala em todo o mundo. A vantagem dessa abordagem é que ela pode ser usada facilmente em prédios existentes, sem introduzir nenhum inconveniente para os proprietários de casas que não sejam intrusivos.

Especificamente, o problema da desagregação de energia pode ser formulado da seguinte forma: Dada a sequência do consumo agregado de energia $X = \{X_1, X_2, \dots, X_n\}$ de N aparelhos ativos no ponto de entrada do medidor em $t = \{1, 2, \dots, T\}$, a tarefa do algoritmo NILM é inferir a contribuição de potência y_t^i do dispositivo $i \in \{1, 2, \dots, N\}$; no tempo t , de modo que, em qualquer ponto do tempo t ,

$$X_t = \sum_{i=1}^N y_t^i + \sigma(t)$$

em que $\sigma(t)$ representa qualquer contribuição dos aparelhos não contabilizado e ruído de medição. O principal desafio para o problema de desagregação de energia é como projetar um algoritmo NILM generalizado eficiente em vários edifícios que podem ser executados em tempo real usando o medidor inteligente. Um algoritmo NILM típico consiste nas seguintes etapas: aquisição de sinal de energia, detecção de eventos, extração de recursos e aprendizado & inferência.

Aquisição de Sinal de Potência

Este é o primeiro passo para qualquer algoritmo NILM e envolve a aquisição de medição de carga agregada a uma taxa adequada para que padrões de carga distintos possam ser identificados.

O sinal de energia agregado desses medidores pode ser gravado em diferentes taxas de amostragem. A frequência de amostragem é determinada pelas medições e características elétricas usadas pelo algoritmo NILM. A frequência de amostragem pode ser de alta ou baixa frequência. (Faustine et al., 2017)

Detecção de eventos

Segundo Faustine et al. (2017), o algoritmo NILM precisa detectar o status de operações do dispositivo (por exemplo, *ON* e *OFF*) das medições de energia. As alterações nos níveis de energia (como *ON / OFF*) são feitas pelo módulo de detecção. É um processo complexo devido aos diferentes tipos de equipamentos nos prédios e ao status diferente a ser detectado, como *ON / OFF* simples, estado finito, constantemente *ON* e status de variável contínua. Com base em diferentes estratégias de detecção de eventos, as abordagens atuais do NILM podem ser classificadas como baseadas em eventos ou em estado.

- **Abordagens baseadas em eventos:** As abordagens baseadas em eventos concentram-se nas arestas de transição de estado geradas pelos dispositivos e usam o algoritmo de detecção de alterações para identificar o início e o fim de um evento. A tarefa do algoritmo de detecção de alterações é detectar alterações nos dados de carga agregada de séries temporais, devido a um ou mais dispositivos serem *ON / OFF* ou alterando seu estado.

As abordagens baseadas em eventos dependem do fato de que a energia monitorada em uma casa está constantemente mudando (subindo e descendo, etapas), como mostrado na Figura 2.3. Essas etapas (se suficientemente significativas) podem ser uma indicação de que um evento ocorreu. Em seguida, as assinaturas do aparelho, como energia ativa, borda crescente / descendente etc. A assinatura dos dispositivos extraídos é analisada para classificar o evento com base no dispositivo e seu consumo de energia estimado.

- **Abordagens baseadas no estado:** As abordagens NILM baseadas em estado não dependem de detectores de eventos; elas representam cada operação de dispositivo usando uma máquina de estado com transição de estado distinta com base no padrão de uso do dispositivo. Eles se baseiam no fato de que, quando o dispositivo é *ON / OFF* ou altera os estados de execução, cria diferentes medições de borda, com uma distribuição de probabilidade que corresponde a esse dispositivo. Os NILMs baseados em estado geralmente são baseados no HMM e suas variantes.

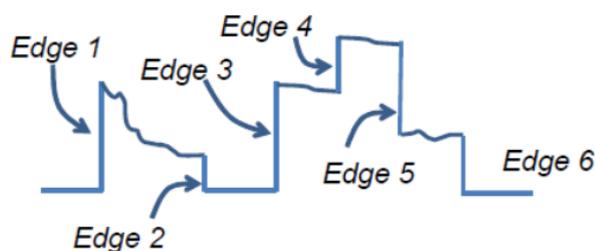


Figura 2.3: Diagrama esquemático das bordas.

Seleção de Recursos

Segundo [Faustine et al. \(2017\)](#), o algoritmo NILM eficaz requer recursos ou assinaturas exclusivas que caracterizam o comportamento do dispositivo. Todos os tipos de aparelhos têm um padrão de consumo de energia exclusivo, frequentemente denominado como assinaturas de aparelhos. Esse padrão de consumo de energia exclusivo é frequentemente usado para identificar e reconhecer exclusivamente as operações do aparelho a partir das medições de carga agregada.

- Assinaturas transitórias: São interrupções de curto prazo em energia ou corrente antes de se estabelecerem em um valor de estado estacionário. Esses recursos definem de forma exclusiva as transições de estado do dispositivo, extraindo recursos como forma, tamanho, duração e harmônicos do transitório. Eles exigem altas taxas de amostragem para obter um alto grau de exclusividade do sinal e maior tempo de monitoramento para capturar todos os ciclos de operação.
- Recursos em estado estacionário: Relacione-se a alterações mais sustentadas nas características de energia quando um dispositivo alterar seus estados de funcionamento. Esses recursos incluem; formas de onda de potência ativa, potência reativa, corrente, corrente e tensão; Apenas para mencionar alguns. A extração da assinatura em estado estacionário não exige dispositivos de medição avançados e pode ser obtida a partir dos valores RMS de corrente e tensão. Recursos de estado estacionário são os recursos mais usados com baixa frequência na literatura.

Aprendizado e Inferência no NILM

Nesta etapa, a assinatura de dispositivos extraídos é analisada para classificar estados específicos de um dispositivo e estimar seu consumo de energia correspondente. Os algoritmos de aprendizado são usados para aprender os parâmetros do modelo, enquanto os algoritmos de inferência são empregados para inferir estados de dispositivo a partir dos dados de energia agregados observados e estimar o consumo de energia correspondente. O algoritmo para aprendizado no NILM pode ser supervisionado ou não supervisionado. ([Faustine et al., 2017](#))

2.2 Algoritmos NILM de última geração

Vários algoritmos não supervisionados do NILM de última geração foram propostos usando abordagens diferentes, como diferentes variantes do HMM, *Graph Signal Processing* (GSP) e *Deep Learning* (Faustine et al., 2017).

Hidden Markov Model

HMM é um modelo de Markov cujos estados não são diretamente observados, em vez disso, cada estado é caracterizado por uma função de distribuição de probabilidade modelando a observação correspondente a esse estado. Existem duas variáveis no HMM: variáveis observadas e variáveis ocultas, nas quais as seqüências de variáveis ocultas formam um processo de Markov. No contexto do NILM, as variáveis ocultas são usadas para modelar estados de aparelhos (*ON*, *OFF*, *standby* etc.) de aparelhos individuais e as variáveis observadas são usadas para modelar o uso elétrico. Os HMMs têm sido amplamente utilizados na maioria das abordagens NILM recentemente propostas, porque representam bem os estados internos de aparelhos individuais que não são diretamente observados no consumo de energia pretendido. (Faustine et al., 2017)

No FHMM, cada um dos n dispositivos (ou circuitos) da casa é descrito por meio de um modelo escondido de Markov (HMM). Cada dispositivo possui um estado oculto discreto, denotado $x_t^{(i)} \in \{1, \dots, N_i\}$ para o estado no momento t do dispositivo i , que corresponde aproximadamente ao estado interno do dispositivo (“desligado” ou em um dos vários estados possíveis de “ligado”). A cada momento t , dado o estado interno, o i -ésimo dispositivo emite uma potência distribuída gaussiana, denotada $y_t^{(i)}$, com parâmetros de média e variância específicos do estado. No entanto, apenas observamos a soma de todas as saídas de energia de cada vez, $\bar{y}_t = \sum_{i=1}^n y_t^{(i)}$. A tarefa de desagregação pode então ser enquadrada como um problema de inferência: dada uma seqüência observada de energia $\bar{y}_1, \dots, \bar{y}_T$, pretendemos calcular a probabilidade posterior capacidade de consumo de dispositivos individuais $y_t^{(i)}$, $i = 1, \dots, n$, $t = 1, \dots, T$. Um modelo de grafos representando essa FHMM é mostrado na Figura 2.4. (Kolter and Johnson, 2011)

Graph Signal Processing

Segundo Faustine et al. (2017), o grafo de processamento de sinal (GSP) é um campo emergente que estende a teoria clássica do processamento de sinal aos dados indexados por grafos gerais. O GSP representa um conjunto de dados usando um grafo de sinal definido por um conjunto de nós e uma matriz de adjacência ponderada. Cada nó do grafo corresponde a um elemento no conjunto de dados enquanto a matriz de adjacência define todas as arestas direcionadas no grafo e seus pesos, onde os pesos atribuídos refletem o grau de similaridade ou correlação entre os nós. O GSP é a abordagem de processamento de sinal poderosa, escalável

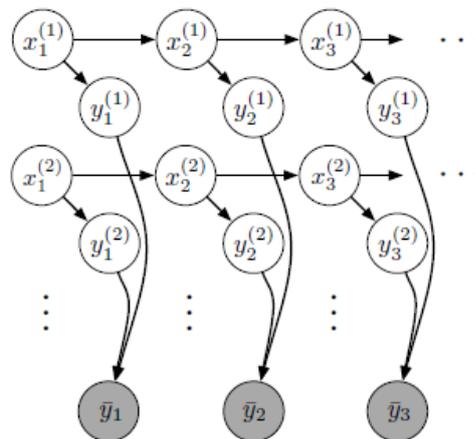


Figura 2.4: Diagrama esquemático do FHMM.

e flexível, adequada para problemas de aprendizado de máquina e mineração de dados. Em particular, o GSP é adequado para problemas de classificação de dados nos quais os períodos de treinamento são curtos e ineficientes para criar modelos de classe apropriados.

Dado um conjunto de medição de potência agregada X , definimos um grafo $G = \{v, A\}$ onde v é o conjunto de nós correspondentes às medições adquiridas e A é a matriz de adjacência ponderada de um grafo que define a borda de um grafo. Cada elemento $x_i \in X$ corresponde a um nó $v_i \in V$ e cada peso $A_{i,j}$ da aresta entre os nós v_i e v_j reflete o grau de relação entre x_i e x_j . O peso de um nó $A_{i,j}$ geralmente é definido usando a função de ponderação gaussiana do kernel, os kernels mais utilizados no aprendizado de máquina para expressar semelhanças entre os conjuntos de dados definidos pela equação

$$A_{i,j} = \exp \left[\frac{-(x_i - x_j)^2}{\rho^2} \right]$$

onde ρ é um fator de escala. Um grafo de sinal é então definido como um mapa nos nós v do grafo para o conjunto de números complexos s , onde cada elemento $s_i \in s$ é indexado pelos nós $v_i \in v$. No contexto da desagregação de energia, cada vértice $v_i \in v$ é associado ao sinal de variação de potência agregada entre a potência adjacente lendo uma amostra ΔX_t ; onde $\Delta X_t = X_{t+1} - X_t$.

Deep Learning

Segundo [Faustine et al. \(2017\)](#), o aprendizado profundo é a abordagem de aprendizado de máquina que se baseia fortemente no conhecimento do cérebro humano (redes neurais artificiais), estatística e matemática aplicada. São as redes neurais artificiais (RNA) que são compostas de várias camadas.

Nos últimos anos, o aprendizado profundo fez melhorias substanciais em vários campos, como visão computacional, reconhecimento de fala e tradução automática. Isso se deve princi-

almente a computadores mais poderosos, conjuntos de dados maiores e técnicas para treinar redes mais profundas. Além disso, modelos de aprendizado profundo são exíveis (permitindo que modelos semelhantes sejam usados em uma ampla gama de problemas). Recentemente, diferentes arquiteturas de aprendizado profundo, como Rede Neural Recorrente (RNN), Rede Neural Convolucional (CNN), codificador automático e uma combinação de aprendizado profundo e HMM, foram empregadas no problema de desagregação de energia.

3

Graph Signal Processing para desagregação de energia

Neste trabalho, é utilizado o algoritmo proposto em [Zhao et al. \(2016\)](#). A Figura 3.2 mostra uma esquematização do algoritmo proposto em forma de fluxograma. Como pode ser visto, a entrada do algoritmo é o consumo de potência agregada $P(i)$, o *threshold* inicial T_0 , o valor de escala σ_0 , e o valor de precisão aceitável K , e a saída são os eletrodomésticos desagregados. Os passos do algoritmo mostrado no fluxograma são descritos com detalhes a seguir. Este algoritmo é feito em 4 partes:

- **Detecção de borda** - utiliza os dados agregados para criar um conjunto ΔP com as variações de potência Φ , indicando que naquele ponto do tempo a potência cresceu (se a variação for positiva) ou diminuiu (se a potência for negativa).
- **Clusterização inicial** - É criado um grafo com esse conjunto e utiliza-se GSP para realizar clusters. Para evitar que os valores de *stand-by* sejam escolhidos, um intervalo inicial de variação de potência é escolhido, de modo que são escolhidos valores fora desse intervalo (os valores são menores que -10 e maiores que 10, e este valor inicial é chamado de T_0 - *threshold* inicial). Quando a clusterização termina, novos valores são escolhidos (T_P , para valores positivos e T_N , para valores negativos), mediante a característica desses clusters.
- **Clusterização refinada** - os clusters são avaliados a partir da fórmula $R_i = \left| \frac{\mu_i}{\sigma_i} \right|$, chamada de desvio padrão relativo, com i sendo o número do cluster e uma constante K , chamada de precisão aceitável do cluster (que segundo [Zhao et al. \(2016\)](#), o valor 0.98 é o que traz o melhor resultado). Os maiores valores de R_i são avaliados como os piores clusters, e então, são comparados com K , se forem maiores que K , a clusterização inicial será feita novamente com esses clusters, até que todos os clusters tenham valor de R_i menor que K .
- **Relação de características** - Os clusters apenas com valores positivos são pareados com os clusters com valores apenas negativos que possuem semelhanças. Daí, dois grafos são gerados, um com as variações de potência e outro com a variação do tempo. Então, usa-se GSP para encontrar os pareamentos ótimos e, se algum par for rejeitado, devido à baixa acurácia, o processo é repetido com esses pares, até que todos os pares tenham sido utilizados no processo.

Por fim, um banco de dados de rótulos é comparado com o resultado final, e tem-se a desagregação com os nomes de seus respectivos eletrodomésticos. O algoritmo utilizado para tal chama-se *Dynamic Time Warping* (DTW), que retorna um número representando a semelhança entre dois vetores, e toma o elemento rotulado no banco de dados e compara com as obtidas na desagregação e, de acordo com o número obtido pelo DTW, as rotulações são realizadas.

Assim funciona o algoritmo de DTW, como descrito em [Liao et al. \(2014\)](#): Sejam $p(1), \dots, p(m)$ e $q(1), \dots, q(n)$ dois eventos. Seja $d(x, y) = |x - y|$ para duas leituras x e y . Sejam

$D(0,0) = 0$ e $D(i,0) = D(0,i) = \infty$, para todo $i > 0$. $D(i,j)$ é a distância DTW acumulada entre os pontos $p(1)$ até $p(i)$ e $q(1)$ até $q(j)$, a $D(n,m)$ é a distância final entre dois vetores.

Após a detecção de eventos e a extração de recursos, a melhor correspondência é encontrada em termos de minimizar a distância $D(n,m)$ entre o evento de teste e todas as assinaturas no banco de dados. Observe que a saída da classificação DTW é um valor flexível - $D(n,m)$ - a distância mínima entre o evento de teste e a melhor janela correspondente. Essa distância mínima é comparada a um limite (*threshold* DTW), que é a distância mínima aceitável entre duas janelas, para classificá-las como uma correspondência. Esse limite é específico do aparelho e depende das variações de estado de cada aparelho, por exemplo, o limite dtw é maior para a máquina de lavar do que a torradeira.

O algoritmo acima é uma forma mais geral do algoritmo proposto por [Zhao et al. \(2015\)](#), e pode ser visto de forma esquematizada na Figura 3.1. Este fluxograma oculta certos passos do algoritmo, como por exemplo, na entrada do algoritmo não é pedido o valor de precisão aceitável K , que é parâmetro no algoritmo mais geral; a redefinição dos valores de *threshold* positivos e negativos e a redefinição do conjunto Φ de clusters a partir desses valores nas fases de clusterização inicial e clustrização refinada, respectivamente; também não menciona como definir que os clusters são finais, e diz que, caso não sejam, salvar os clusters finais e reduzir pela metade o parâmetro σ , enquanto que na versão mais geral do algoritmo, é dito que novos grafos são gerados do novo conjunto Φ , e define como clusters finais aqueles que possuem $R_i \leq K$ e, caso contrário, salva os que possuem $R_i \geq K$, remove-os de Φ e reduz σ pela metade; na fase de relacionar características, é dito apenas que os elementos positivos e negativos devem ser relacionados utilizando GSP, omitindo a parte que dois grafos são gerados, um com os vértices sendo ΔP e outro com os nós sendo a duração Δt e que o GSP é utilizado para identificar os pares de bordas ascendentes e descendentes ótimos.

A seguir, é apresentada uma descrição da base de dados utilizada neste trabalho.

3.1 Datasets

3.1.1 Conjunto de dados (*Dataset*) REDD

O *dataset* REDD foi proposto por [Kolter and Johnson \(2011\)](#), e é uma base de dados especificamente voltada para a tarefa de desagregação de energia. O REDD consiste no consumo de eletricidade específica de toda a casa e do circuito/dispositivo durante um número de casas reais durante vários meses. Todo o sinal de eletricidade da casa (monitores de corrente em ambas as fases de energia e um monitor de voltagem em uma fase) gravados em alta frequência (15kHz); até 24 circuitos individuais em casa, cada um identificado com sua categoria de equipamento ou aparelho, registrado em 0,5 Hz; até 20 monitores de nível de plugue em casa, gravados em 1 Hz, com foco em dispositivos eletrônicos de registro em que vários dispositivos são agrupados em um único circuito.

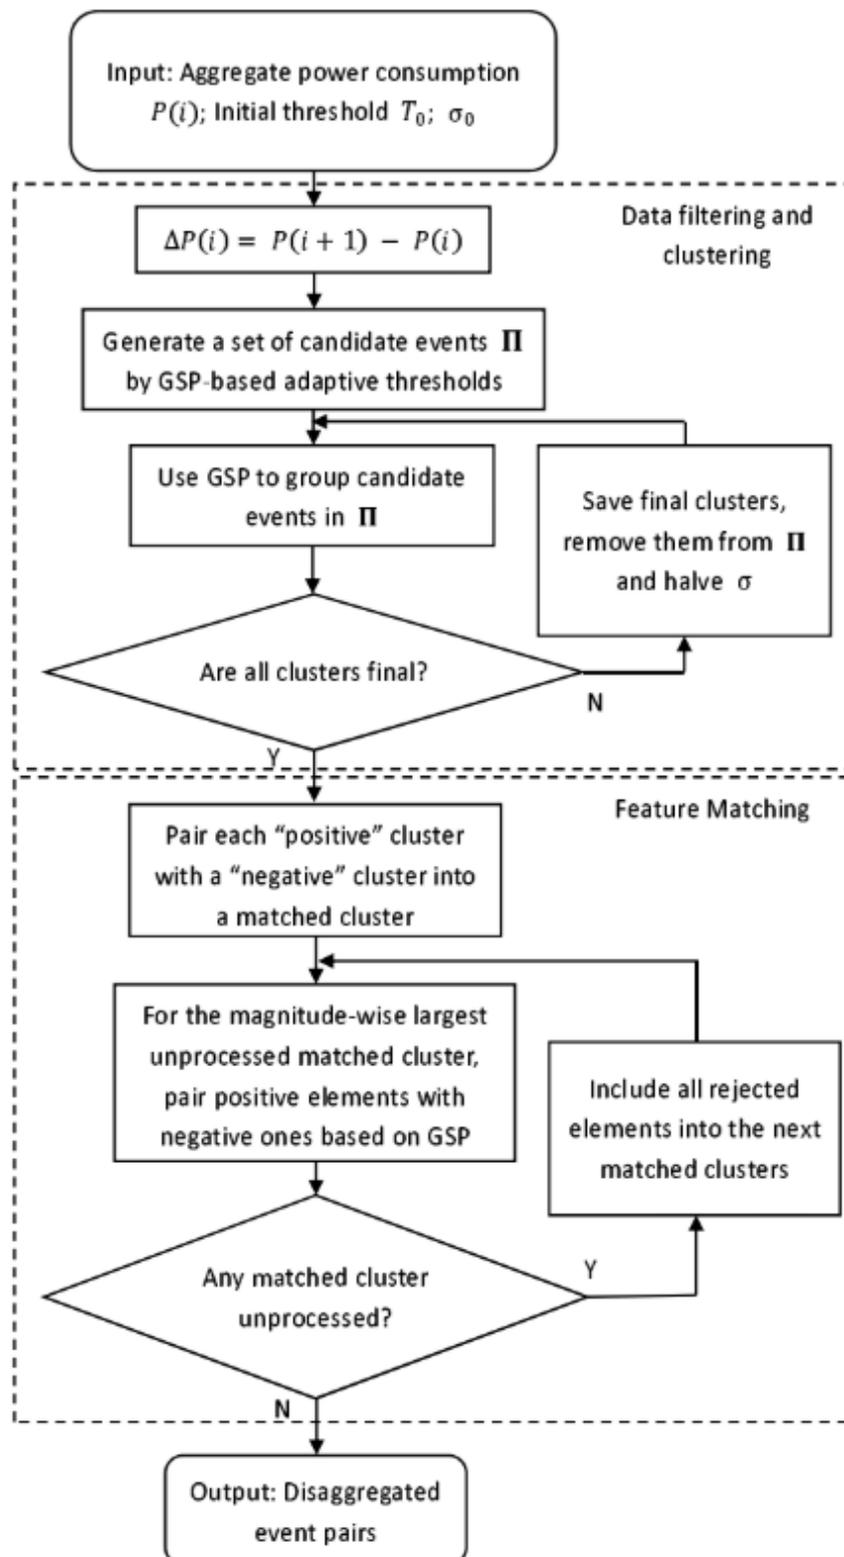


Figura 3.1: Fluxograma do algoritmo proposto em Zhao et al. (2016)

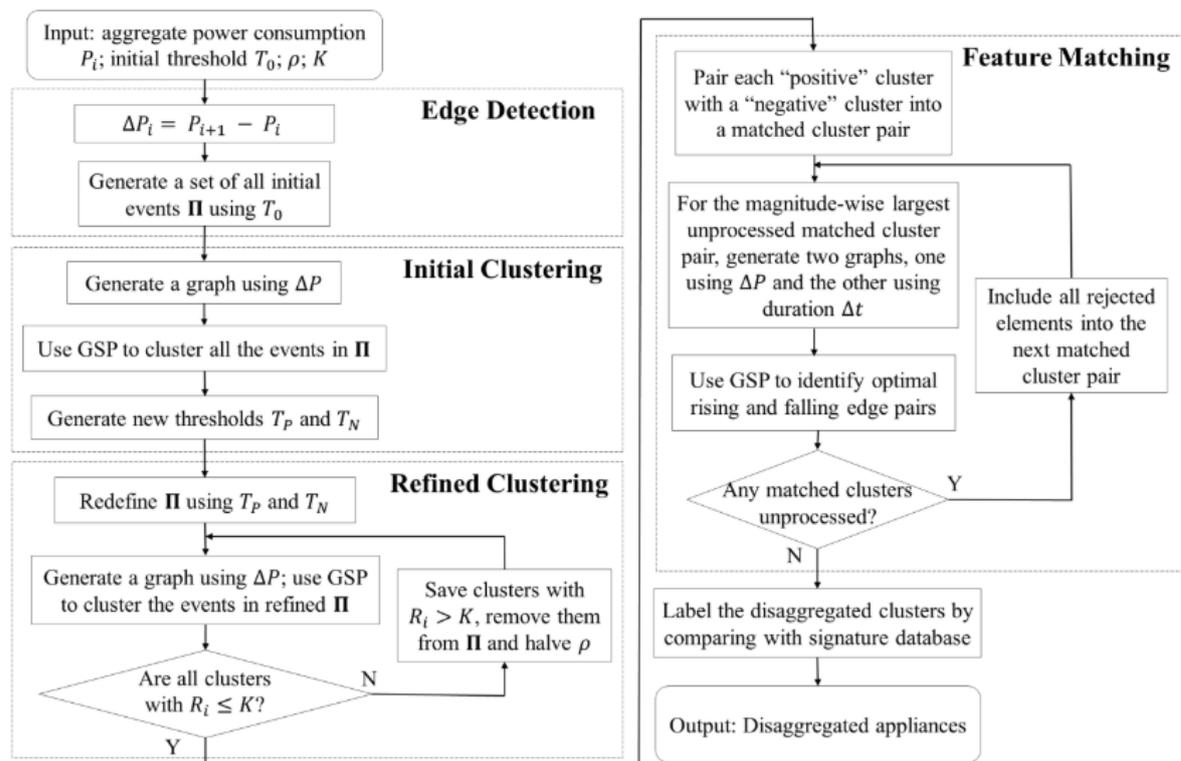


Figura 3.2: Fluxograma do algoritmo proposto em Zhao et al. (2015)

A base de dados disponível no site do *dataset* possui dados de 6 casas, porém, Kolter and Johnson (2011) relata que até 15 de junho de 2011, havia 10 domicílios monitorados, com um total de 119 dias de dados (combinados em todos os domicílios), 268 monitores únicos, e mais de 1 terabyte de dados brutos e, à época, REDD representa o maior conjunto de dados publicamente disponíveis para desagregação com as cargas reais de cada casa identificadas.

A Figura 3.3 mostra como se deu o processo de coleta de dados para a formação da base. Os dados dados a nível de plug são coletados através de tomadas da marca *Enmetric*, que possui um servidor para onde esses dados são chamados através de um roteador. Os dados no nível do circuito e os dados de toda a casa exigem uma configuração mais envolvida. A nível de circuito é usado o *eMonitor*, que vem com transformadores de corrente (TCs) que são conectados a cada circuito individual da casa no painel de disjuntores de uma casa. Utilizando sua API, os dados foram coletados a cada 3 segundos. A nível da casa inteira, é utilizado um TED (*The Energy Detective*), um osciloscópio e um conversor analógico-digital NI-9239 para a conversão dos sinais vindos do osciloscópio. Todos os dados são enviados para um laptop, que registra os dados e envia um subconjunto dos dados brutos ao servidor central do REDD.

Kolter and Johnson (2011) ainda utiliza o algoritmo FHMM para desagregar os dados agregados para comprovar eficácia comparando com os dados coletados de eletrodomésticos.

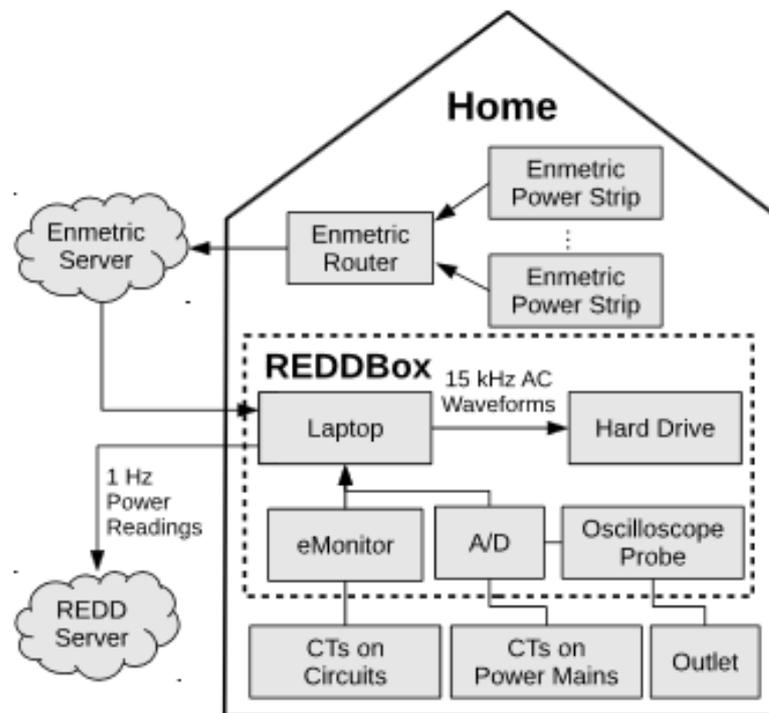


Figura 3.3: Esquemático que mostra o processo de coleta dos dados do REDD.

3.1.2 Conjunto de dados (*Dataset*) REFIT

O REFIT é um *dataset* criado, segundo o seu próprio website (<https://www.refitsmarthomes.org/>), para estudar a redução da demanda de energia doméstica e as contas de energia do consumidor.

O REFIT é um projeto de pesquisa ambicioso e altamente interdisciplinar, com o objetivo de longo prazo de criar uma mudança nas taxas de adoção de medidas de tecnologia de modernização em residências no Reino Unido. O projeto reúne uma equipe de pesquisa diversificada, com expertise de renome internacional em edifícios, energia, TIC, pessoas e design. O REFIT estudará o conceito Smart Home e sua capacidade de fornecer informações personalizadas, valorizadas, personalizadas e confiáveis sobre modernização de edifícios, eficiência energética e opções de tecnologia renovável no local para residências no Reino Unido.

O REFIT possui 4 *datasets* abertos, porém, o utilizado neste trabalho, é o citado em Murray et al. (2015). Os dados são coletados a cada 8 segundos e destina-se a ser usado em pesquisas sobre conservação de energia e serviços avançados de energia, desde monitoramento não invasivo da carga de aparelhos, medidas de resposta à demanda, aconselhamento personalizado de energia e modernização, análise de uso de eletrodomésticos, análise de uso de eletrodomésticos, estatísticas de consumo e uso de tempo e estatísticas de uso doméstico inteligente/automação predial.



Resultados e Discussões

4.1 Resultados e Discussões

Os resultados foram obtidos a partir do código em Python contido no repositório https://github.com/loneharoon/GSP_energy_disaggregator.git, que é a tradução para Python do código em MATLAB implementado pelo autor da proposta, e reproduz o algoritmo proposto em Zhao et al. (2016), e utiliza como demonstração para a execução do algoritmo uma base de dados coletados a cada 1 minuto. Em Zhao et al. (2016), os autores utilizam como estudo de caso as casas 1, 2 e 6 do *dataset* REDD, e da casa 8 do *dataset* REFIT.

4.1.1 Pré-processamento

A princípio, foi necessário fazer um pré-processamento com os dados dos *datasets* utilizados na aplicação do algoritmo. A implementação do algoritmo importa três formatos de arquivos CSV (Comma-Separated Values - um tipo de planilha que separa os valores das colunas por vírgulas, espaços, pontos etc.): uma planilha com os dados agregados da residência (energia que vem do poste para a residência); uma planilha contendo os dados desagregados (dados coletados de cada eletrodoméstico individualmente) e uma planilha contendo as assinaturas das casas (dados que representam as detecções de borda dos sinais agregados). Cada planilha, exceto a de assinaturas, contém uma coluna de dados de data/hora, utilizada como índice pelo algoritmo para a geração dos gráficos de potência em função da data/hora.

A linguagem R foi utilizada para o pré-processamento dos dados, ou seja, os dados foram transformados de forma que o algoritmo possa lê-los, tanto a planilha de dados agregados quanto a planilha de dados desagregados. Os dados desagregados do REDD estavam contidos em planilhas separadas. Então, foi necessário incluir os dados desagregados em uma única planilha, e a coluna de data/hora foi retirada de uma planilha arbitrária, já que ela era a mesma para cada uma. A data/hora estava em formato de *Timestamp Unix* (contagem de segundos desde o dia 01 de janeiro de 1970, ao meio-dia, que representa o marco zero do sistema de calendário usado pelo sistema operacional *Unix*, segundo https://pt.wikipedia.org/wiki/Era_Unix), que foram convertidos para o formato de data/hora utilizando o R. As duas planilhas de dados agregados possuíam também a data/hora nesse formato e a conversão foi realizada com eles. Foram gerados, então, os arquivos *house1_aggr.csv*, *house1_aggr2.csv* e *house1_disaggr.csv* para a casa 1 do REDD, por exemplo; para as outras residências é só fazer a substituição do número 1 pelo 2, pelo 6 ou pelo 8, caso seja a casa 8 do REFIT, e se quiser utilizar uma das *mains* é só colocar um número 2 após o nome *aggr* para a *main* 2 e nenhum número para a *main* 1. Para o REFIT o pré-processamento foi mais fácil, pois os dados agregados e desagregados constavam na mesma planilha, portanto, as alterações foram mínimas, como nos nomes dos eletrodomésticos; ao invés de *Washing Machine* foi colocado *washing_machine*, para que fosse mais fácil de o algoritmo interpretar. O motivo para a escolha da linguagem R foi a versatilidade de sua IDE, o R

Studio, para esse tipo de operação.

A planilha de assinaturas foi gerada pelo próprio algoritmo. Ele possui uma função chamada *generate_appliance_powerseries*, que retorna as detecções de borda, num formato próprio. O algoritmo utiliza planilhas de demonstração que foram coletados de uma determinada fonte entre os dias 23 e 30 de abril de 2011, de minuto a minuto. O algoritmo gerou os dados de assinaturas a partir da função citada, utilizando uma amostra das coletas, de 28 a 30 de abril de 2011. Para a execução do DTW com os dados do REDD e do REFIT, foram coletadas as assinaturas de um intervalo de tempo de um dia inteiro de ambos. A rotulação das assinaturas contidas nos arquivos foi feita seguindo a orientação do próprio artigo, de que se as assinaturas não estiverem rotuladas, são dados nomes quaisquer à elas e, após o término da execução do algoritmo, os dados são comparados e rotulados corretamente,

4.1.2 A desagregação

Após o término do pré-processamento, as bases de dados foram utilizadas para a desagregação. Conforme foi feito no artigo, apenas alguns eletrodomésticos foram utilizados de cada residência, não todos. Na casa 1 do REDD, foram utilizados: *refrigerator*, *dishwasher*, *kitchen_outlets*, *lighting*, *washer_dryer*, *bathroom_gfi*, *microwave* e *oven*; na casa 2 do REDD, foram utilizados: *microwave*, *kitchen_outlets*, *kitchen_outlets2*, *stove*, *refrigerator*, *dishwasher* e *lighting*; na casa 6 do REDD, foram utilizados: *microwave*, *kitchen_outlets1*, *stove*, *refrigerator*, *electronics*, *electric_heat*, *air_conditioning*, *lighting* e *outlets_unknown* e na casa 8 do REFIT: *microwave*, *toaster*, *kettle*, *refrigerator*, *freezer*, *television_site* e *washing_machine*.

Os parâmetros utilizados para a desagregação no artigo foram: $\sigma = 20$, $r_i = 0,5$, $T_0 = 10$ (o que significa $(-\infty, -10) \cup (10, \infty)$), $\alpha = \beta = 0,5$, *instancelimit* = 3 (valor que indica o número de vezes que o eletrodoméstico esteve ligado) e $R = 0,98$. Foi, também, utilizada, uma amostra de 3 dias, de cada base de dados.

Neste trabalho, o algoritmo foi executado utilizando as bases de dados mencionadas, com os parâmetros citados anteriormente e com dados de três dias de coleta. O intervalo de tempo foi escolhido arbitrariamente, supondo que o algoritmo funcionaria para qualquer intervalo escolhido das bases de dados. Os resultados das desagregações das casas do REDD são mostrados nas Figuras 4.1 e 4.2, para as duas *mains* da casa 1, 4.3 e 4.4, para as duas *mains* da casa 2, e 4.5 e 4.6, para as duas *mains* da casa 6; e 4.7, para a casa 8 do REFIT. Os resultados das desagregações para os valores dos parâmetros citados no parágrafo anterior retornou muito mais eletrodomésticos do que os eletrodomésticos das suas respectivas bases de dados, tanto para as casas do REDD quanto para as casas do REFIT utilizadas. A maioria destes eletrodomésticos obtidos pelo algoritmo foram rotulados como desconhecidos (*Unknown*), que, segundo o artigo definiu, são os eletrodomésticos que assemelham-se não só à um único eletrodoméstico, mas à mais de um. Até os que assemelham-se à um único eletrodoméstico não assemelham-se tanto quanto o que se esperava. As figuras referenciadas neste parágrafo mos-

tram os eletrodomésticos desagregados obtidos pelo algoritmo que mais assemelham-se aos da base de dados de eletrodomésticos desagregados das bases (também chamado de *Ground Truth*).

Na primeira *main* da casa 1 do REDD (Figura 4.1), foi rotulado, em azul, *refrigerator*, no terceiro gráfico. Notam-se 5 picos, no dia 18 de abril, próximo das 23 horas, no dia 19 de abril, próximo das 11 horas, no dia 19 de abril, um pouco depois das 23 horas, entre as 23 horas dos dias 19 e 20 de abril e próximo das 23 horas do dia 20 de abril. Ao observar o *ground truth*, em azul (segundo gráfico), o gráfico do *refrigerator* é periódico, com poucas alterações na potência máxima. Em cinza, no terceiro gráfico, próximo das 23 horas, no dia 18, nota-se que este coincide com o segundo, em cinza, no mesmo ponto, e foi rotulado com *oven*; porém, próximo das 11 horas do dia 20, ele coincide com *microwave* em um ponto e *bathroom_gfi* em outro e, ao longo do tempo, os picos diferem do gráfico de *oven*. Poderia ser rotulado como *Unknown*, porém, era o mais próximo de *oven*. O vermelho, no terceiro gráfico, foi rotulado como *lighting*, ele assemelha-se ao que está em vermelho no segundo gráfico, porém, nota-se que ele está um pouco deslocado, às 11 horas do dia 20 de abril no terceiro, e no segundo, está próximo disso, porém um pouco antes. O marrom foi rotulado como *bathroom_gfi*, porém, assemelha-se à *dishwasher*, observando o *Ground Truth*, porém, este está um pouco mais deslocado à esquerda, próximo do dia 18 de abril às 23 horas, porém, na previsão, saiu um pouco antes. O roxo foi rotulado como *washer_dryer*, que tem uma semelhança com o do *Ground Truth* próximo do dia 19 de abril às 11 horas e próximo do dia 22 de abril às 23 horas. O verde foi rotulado como *kitchen_outlets*, que assemelha-se ao *Ground Truth* próximo do dia 22 de abril às 11 horas. O laranja foi rotulado como *dishwasher*, porém, não assemelha-se à nenhum. Estes foram os que chegaram próximos do resultado esperado, embora alguns devessem ser mesmo rotulados como *Unknown*.

Na segunda *main* da casa 1 do REDD (Figura 4.2), nota-se que o cinza, rotulado como *oven*, assemelha-se ao do *Ground Truth*, e foi medido próximo ao dia 18 de abril às 23 horas. O roxo, que foi rotulado como *washer_dryer*, assemelha-se mais à *dishwasher* no *Ground Truth*, no dia 18 de abril às 23 horas. O vermelho foi rotulado como *lighting*, porém, um pouco deslocado do valor que está no *Ground Truth*, foi detectado no dia 18 de abril às 23, enquanto que no *Ground Truth* foi próximo disso, porém, um pouco depois. No dia 18 de abril, foi detectada uma ocorrência de *microwave*, em rosa, que se assemelha ao *Ground Truth*; uma também, próximo das 23 horas, no mesmo dia. O laranja foi rotulado como *dishwasher*, porém, não há muita semelhança com o esperado. Em azul, *refrigerator*, que teve 3 picos, um próximo às 23 horas do dia 18, um próximo do dia 19 às 11 e um próximo do dia 20 às 23, enquanto que o esperado é que ele fosse periódico. Ao longo do período, o algoritmo detectou ocorrências de *kitchen_outlet*, em verde, porém, com valores de potência muito baixos e muito distante do original. Os demais eletrodomésticos detectados pelo algoritmo foram classificados como *Unknown*.

Na primeira *main* da casa 2 do REDD (Figura 4.3), nota-se que o rosa, que foi rotulado como *lighting*, assemelha-se à *dishwasher* no *Ground Truth*, porém, com um deslocamento;

enquanto que o esperado é que ele fosse medido no dia 18 de abril às 13, ele foi medido próximo à essa data e hora, porém, um pouco antes e ao longo do período medido, ele não se assemelha tanto à *dishwasher*. Os demais foram difíceis de reconhecer, foram rotulados arbitrariamente.

Na segunda *main* da casa 2 do REDD (Figura 4.4), também é muito difícil de reconhecer o resultado obtido. O roxo foi rotulado como *refrigerator* e assemelha-se um pouco, principalmente entre os dias 20 de abril às 13 horas e 21 de abril à 1 hora. É possível ver alguns picos de potência que assemelham-se ao original, porém, não no intervalo escolhido todo. Em marrom, *dishwasher*, assemelha-se com o esperado, porém, o algoritmo o detectou próximo da 1 da manhã do dia 21 de abril, e o esperado o detectou às 13 horas do dia 18 de abril. Os demais, como no caso da *main*, foram rotulados arbitrariamente, supondo que o algoritmo iria detectar os eletrodomésticos na sequência que eles aparecem no *Ground Truth*, porém, eles devem ser rotulados como *Unknown*.

Na primeira *main* da casa 6 do REDD (Figura 4.5), nota-se, que o gráfico verde, rotulado como *refrigerator* realmente se assemelha com o gráfico em verde do *Ground Truth*, porém, com um deslocamento, no *Ground Truth*, as medições de *refrigerator* aparecem antes de 21 de maio às 19 horas até o dia 22 de maio entre 1 e 7 horas; e a predição detecta *refrigerator* um pouco antes 22 de maio até o fim do intervalo escolhido, que foi 24 de maio. o gráfico em rosa foi rotulado como *lighting*, que assemelha-se ao do *Ground Truth*, principalmente no dia 22 de maio às 13 horas e no dia 23 de maio, à 1 hora. Entre os dias 22 de maio, da 1 às 13, a previsão não foi eficaz, com potências próximas do zero. O azul foi rotulado como *kitchen_outlets*, que não possui semelhança com o gráfico de *kitchen_outlets* do *Ground Truth*. É interessante observar que no dia 22 de maio, pouco depois das 13 horas, foi detectado um pico de potência, que não tem correspondência no *Ground Truth*, mas tem correspondência no gráfico da *main*. O mesmo acontece com o gráfico predito em vermelho, que foi rotulado como *electronics*, entre 23 de maio às 19 horas e 24 de maio à 1 hora, e com o gráfico em verde, no dia 23 de maio, entre às 7 e às 13 horas; e com os que foram rotulados *air_conditioning* (em marrom) e *electronics* (em vermelho), próximo do dia 22 de maio, às 13 horas (o que foi rotulado como *washer_dryer* não possui semelhança com nenhum, poderia ser rotulado como *Unknown*). Estas predições foram feitas justamente no período onde o *Ground Truth* tem ruídos (a partir do dia 22 de maio, à 1 hora), como relatado na Seção 1.5 do Capítulo , portanto, não é possível fazer uma rotulação correta dos eletrodomésticos encontrados.

Na segunda *main* da casa 6 do REDD (Figura 4.6), como na primeira *main* desta casa, as predições foram encontradas no período do ruído do *Ground Truth* desta casa. Nenhuma das predições nesta *main* são consistentes, talvez no dia 23 de maio, entre 1 e 7 horas, que, como na primeira *main*, parecem com os picos da potência agregada no mesmo período, porém, não é garantido que a rotulação é de fato a que foi feita, por causa do ruído no *Ground Truth*. Próximo ao dia 24 de maio, à 1 hora, o *Ground Truth* mostra uma coleta bem discreta de *electronics*, e na predição, no mesmo horário, há uma coleta bem discreta também, no mesmo horário (um

pouco depois), este poderia ser rotulado, então, como *electronics*.

Na casa 8 do REFIT (Figura 4.7), os eletrodomésticos foram rotulados arbitrariamente, porém nenhum se parece com os do *Ground Truth*. Todos poderiam ser rotulados como *Unknown*.

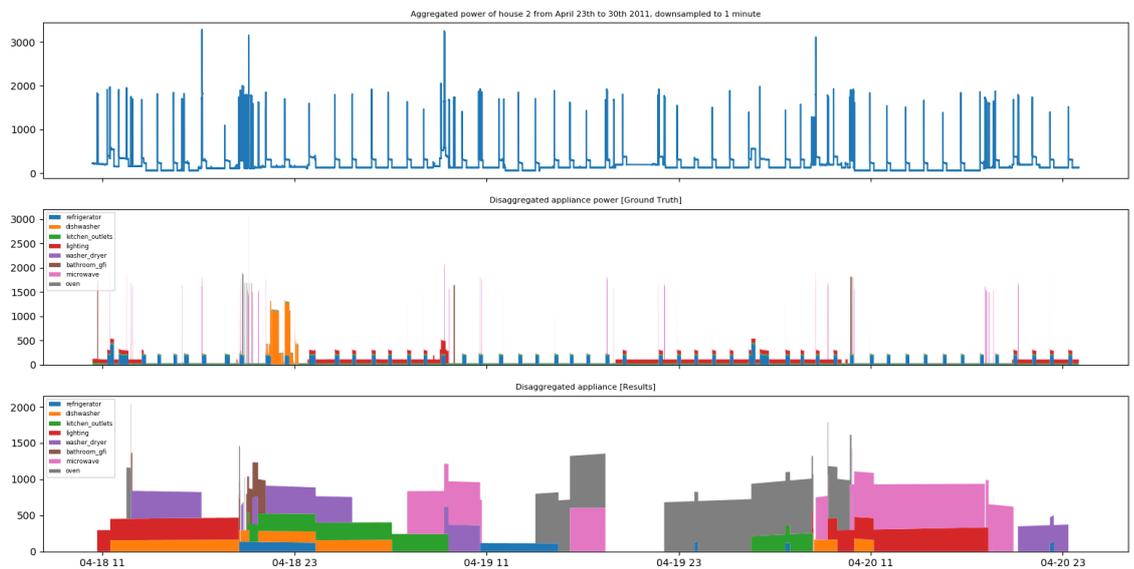


Figura 4.1: Comparação da desagregação feita com os dados da primeira *main* da casa 1 do REDD com os dados desagregados da mesma casa.

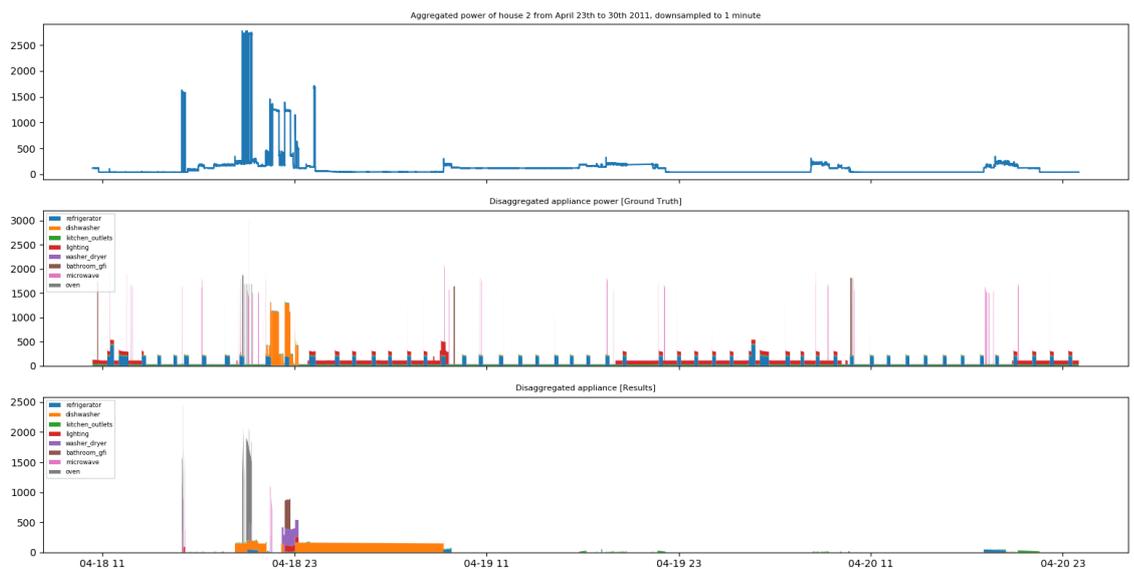


Figura 4.2: Comparação da desagregação feita com os dados da segunda *main* da casa 1 do REDD com os dados desagregados da mesma casa.

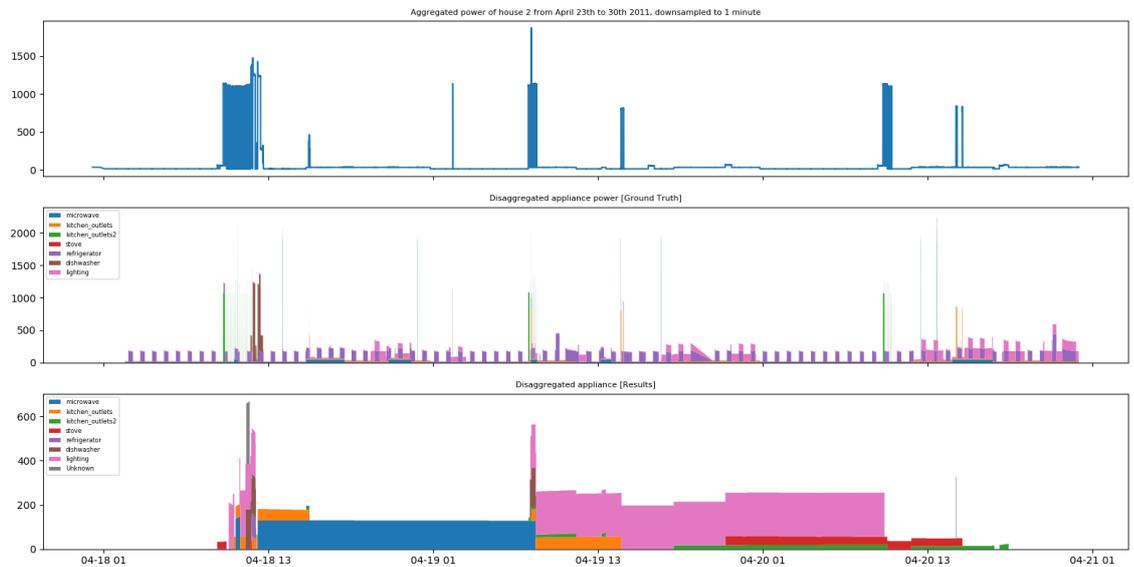


Figura 4.3: Comparação da desagregação feita com os dados da primeira *main* da casa 2 do REDD com os dados desagregados da mesma casa.



Figura 4.4: Comparação da desagregação feita com os dados da segunda *main* da casa 2 do REDD com os dados desagregados da mesma casa.

Os parâmetros foram, então, modificados, buscando uma melhor representação dos eletrodomésticos obtidos pelo algoritmo. Foi notado que os parâmetros que causam uma mudança significativa no resultado são o σ , o r_i e o *instancelimit*. As Figuras 4.8 e 4.9 mostram as de-



Figura 4.5: Comparação da desagregação feita com os dados da primeira *main* da casa 6 do REDD com os dados desagregados da mesma casa.

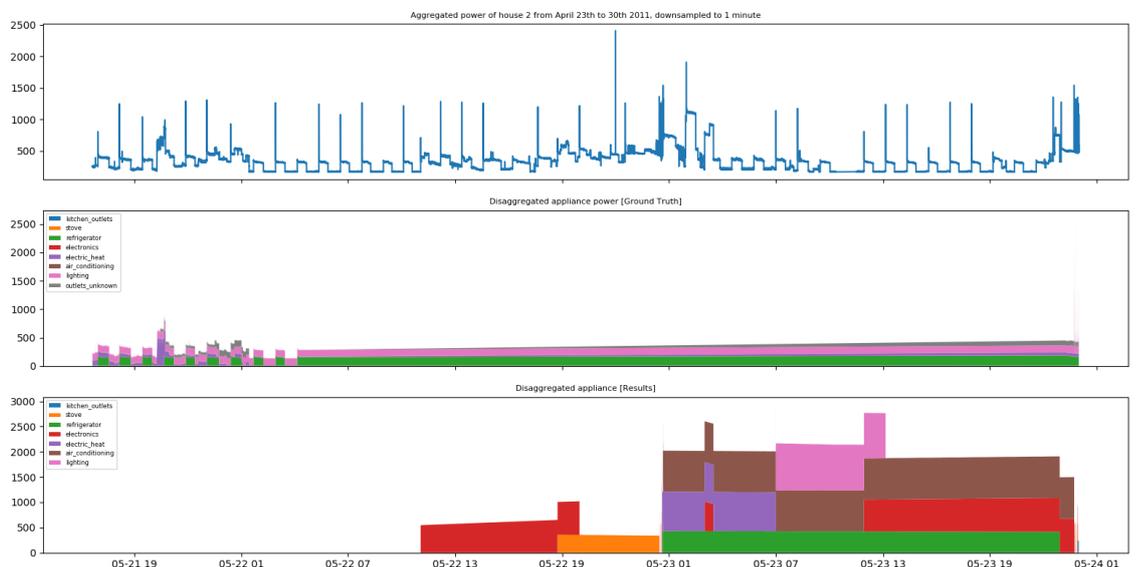


Figura 4.6: Comparação da desagregação feita com os dados da segunda *main* da casa 6 do REDD com os dados desagregados da mesma casa.

sagregações das *mains* da casa 1 do REDD, os parâmetros utilizados foram $r_i = 0,75$ para a *main* 1 e $r_i = 0,8$ e *instancelimit* = 2 para a *main* 2. Percebe-se uma mudança significativa na qualidade dos eletrodomésticos obtidos, principalmente nos eletrodomésticos *refrigerator* (em

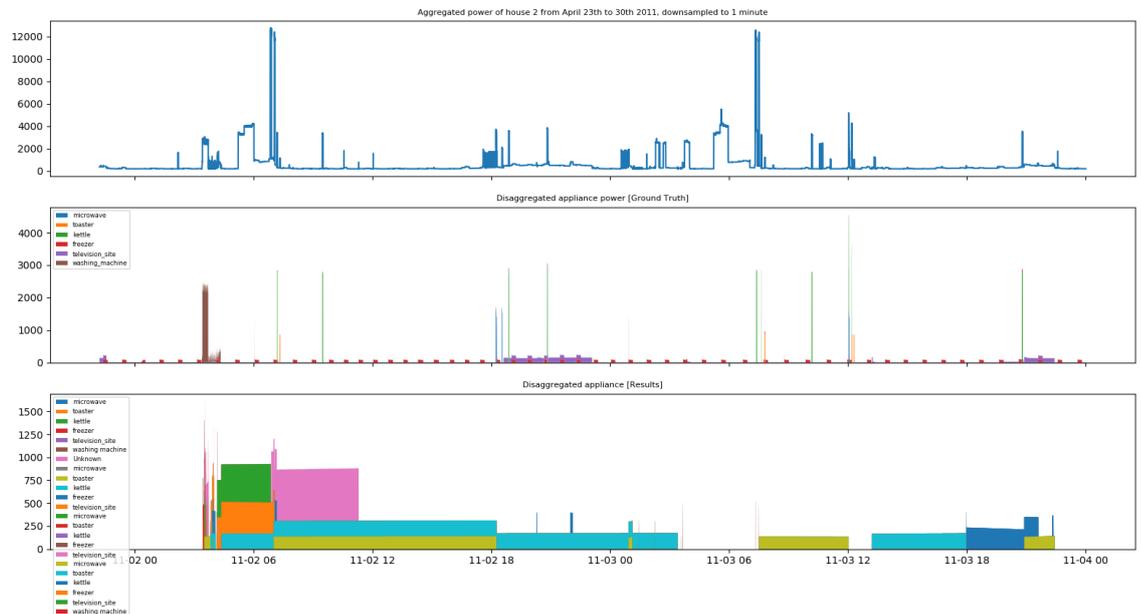


Figura 4.7: Comparação da desagregação feita com os dados da casa 8 do REFIT com os dados desagregados da mesma casa.

azul), *washing_machine* (em roxo) e *lighting* (em verde) na *main 1* e *dishwasher* (em amarelo) e *microwave* (em marrom) na *main 2*. A partir daí, pode-se argumentar que os eletrodomésticos não utilizam a energia de uma única *main*, e sim, "selecionam" uma *main* para fazer o uso dela.

Na primeira *main* da casa 1 do REDD (Figura 4.8), a mudança dos parâmetros retornou 6 eletrodomésticos. *refrigerator*, rotulado em azul, apresentou um pouco mais de detalhes que o gráfico anterior, com os parâmetros utilizados pelo artigo. Porém, ao comparar com o *Ground Truth*, onde o gráfico é periódico, e os picos são quase iguais, e do mesmo período, o detectado pelo algoritmo apresentou picos de tamanhos variados; no dia 1º de maio, pouco depois das 7 horas, os picos são menores, e em intervalos menores que os que aparecem próximo do dia 2 de maio, às 7 horas; nota-se, também, que no dia 1º de maio às 19 horas, os picos são ainda menores que os falados anteriormente, e pouco depois do dia 3 de maio às 7 horas, um pico maior. Portanto, *refrigerator* apareceu com mais detalhes, porém, com picos de tamanhos diferentes. *dishwasher*, em laranja, poderia ter sido classificado com *Unknown*. O verde foi rotulado como *microwave*, porém, assemelha-se mais à *kitchen_outlets*, sobretudo pouco depois do dia 1º de maio às 7 horas, com o pico reduzido em relação ao *Ground Truth*, os demais picos em verde, como o do dia 2 de maio, pouco depois das 7 horas, é um pico muito grande e não corresponde ao real. O vermelho, rotulado como *lighting*, assemelha-se ao original no primeiro pico, antes das 7 horas do dia 1º de maio e antes das 19 horas do mesmo dia. Em ambos, a potência é na ordem dos 1000 W, porém, neste último, as potências coletadas de *lighting* em períodos próximos não são tão altas; os outros picos em vermelho, entre às 7 e às 19 horas do dia 2 de maio e depois das 19 horas deste mesmo dia também, porém não

correspondem à realidade, ao comparado com o *Ground Truth*. Em, roxo, *washer_dryer*, há duas ocorrências, as duas próximo das 19 horas do dia 1º de maio, o algoritmo as detectou, porém, os picos foram muito maiores que os do *Ground Truth*, e com as potências muito altas (no *Ground Truth* menores que 1000 W e próximas à 3000 W na predição do algoritmo). O marrom foi rotulado como *bathroom_gfi*, que não assemelha-se ao do *Ground Truth*, porém, ao comparar com a medição agregada, o gráfico em marrom tem um pico de 5000 W, no mesmo local que a medição em marrom (às 19 horas do dia 1º de maio); que não corresponde à nenhum pico no *Ground Truth*, é possível que seja um ruído.

Na segunda *main* da casa 1 do REDD (Figura 4.8), a mudança dos parâmetros retornou 6 eletrodomésticos. O azul, rotulado como *refrigerator* detectou menos picos que na primeira *main*; três picos antes das 7 horas do dia 1º de maio, onde, no mesmo período no *Ground Truth*, há apenas 2, no mesmo dia às 19 horas, há um pico maior e outro pouco depois das 7 horas do dia 3 de maio. Rotulado em amarelo, *dishwasher*, depois das 7 horas do dia 3 de maio, foi o único período detectado pelo algoritmo; e há um registr, no mesmo período, no *Ground Truth*, de *dishwasher*, porém, nesse registro, as potências são variadas, algumas menores que 1000 W e algumas maiores, mas sempre nessa faixa, e os picos detectados pelo algoritmo aproximam-se dos 500 W, mais ou menos. O verde foi rotulado como *microwave*, porém, é mais próximo de *kitchen_outlets*, porém, os picos detectados pelo algoritmo eram de duração muito longa, dois picos coincidem com os picos em azul, como no *Ground Truth*, antes das 7 horas do dia 1º de maio, e um pico que coincide com *dishwasher*, pouco depois das 7 horas do dia 3 de maio, que como *dishwasher*, no *Ground Truth*, há uma variação dos picos, na faixa de 500 W a quase 2000 W, e o detectado neste horário, em verde, foi próximo de 500 W. Como na primeira *main*, *washer_dryer*, rotulado em roxo, os picos foram no dia 1º de maio às 19 horas, e o pico era muito alto, no *Ground Truth* é próximo de 1000 W, enquanto que no algoritmo, é próximo de 2000 W. O marrom, rotulado como *bathroom_gfi*, como na primeira *main*, coincide com os dados agregados, e não com o *Ground Truth*. O vermelho, que foi rotulado como *lighting*, é próximo da potência de *lighting* do *Ground Truth*, porém, os picos não condizem com o *Ground Truth*, pois os picos são muito longos, há um pico maior às 7 horas do dia 1º de maio, porém, neste horário não há medições, e não se assemelham à medições nos horários próximos.

Na primeira *main* da casa 2 do REDD (Figura 4.10), a mudança dos parâmetros retornou 7 eletrodomésticos. *microwave*, em azul, assemelha-se muito ao do *Ground Truth*, porém neste, os picos são mais longos, enquanto que os encontrados pelo algoritmo, próximo do dia 18 de abril, às 13 horas; no dia 19 de abril, entre 1 e 13 horas, os picos coincidem, alguns depois das 13 horas desse mesmo dia coincidem com um pico do *Ground Truth*, e no dia 20 de abril, às 13 horas, o algoritmo detectou um pico maior, que comparado com o *Ground Truth*, aparece pouco antes deste. Em amarelo, *kitchen_outlets*, coincide com o gráfico em azul, *microwave*, como no *Ground Truth*, porém, as potências são mais altas, no *Ground Truth* as potências de *kitchen_outlets* são mais próximas do zero, enquanto que nas medições do algoritmo, as medições chegam a cerca de 250 W. O verde foi rotulado como *Unknown* e realmente não

assemelha-se à nenhum gráfico. O vermelho, *stove*, mal aparece no *Ground Truth*, então não é possível comparar. O pico que foi rotulado como *refrigerator*, em roxo, aparece próximo do dia 18 de abril, às 13 horas, porém, não é possível que este represente *refrigerator*, pois é um único pico com a potência entre 500 e 1000 W, enquanto que *refrigerator* são picos periódicos e com a potência menor, próximo dos 100 W; próximo das 13 horas do dia 20 de abril há um pico entre 500 e 1000 W, que corresponde ao *refrigerator* do *Ground Truth*. Próximo das 13 horas do dia 20 de abril, aparece *dishwasher* em marrom, que não tem correspondências no *Ground Truth*, mas tem uma correspondência com *kitchen_outlets2* no *Ground Truth*, antes desse horário. O rosa foi rotulado como *lighting*; próximo do dia 18 de abril, às 13 horas, aparecem 3 picos em rosa, com potências próximas de 1500 W, neste mesmo horário, há potências semelhantes no *Ground Truth*, porém, na previsão, algumas coincidiram, e algumas ficaram deslocadas. Algumas coincidem com as do *Ground Truth* entre 1 e 13 horas do dia 19 de abril, e algumas horas depois das 13 horas desse mesmo dia; no *Ground Truth*, algumas potências de *lighting* coincidem com o azul, *microwave*, e entre 1 e 13 horas do dia 19 de abril até antes das 13 do dia 20 de abril os picos de *lighting* coincidem com os de *microwave*, mas as potências são muito altas, a previsão foi da mesma potência para todos (na faixa dos 1500 W), porém, na realidade, não é sempre assim, só em alguns picos.

Na segunda *main* da casa 2 do REDD (Figura 4.11), a mudança dos parâmetros retornou 8 eletrodomésticos. O verde e o cinza foram rotulados como *Unknown*. O roxo, rotulado como *refrigerator*, entre os dias 19 e 20 de abril, o algoritmo conseguiu prever uma caída, que foi detectada pelo *Ground Truth*, próximo das 13 horas do dia 19, próximo da 1 hora do dia 19 e às 13 horas do dia 20 de abril, foram detectados os picos que mais se assemelham aos do *Ground Truth*, porém, com o tempo maior do que deveria ser, algumas deveriam ser zero, como entre os dois picos entre os dias 19 e 20 de abril e depois do pico à 1 hora do dia 19. *stove*, em vermelho, não é possível comparar, pois não é possível localizá-lo no *Ground Truth*. O rosa, rotulado como *lighting*, tem um pico próximo do dia 21, à 1 hora, que foi detectado pelo algoritmo, porém, no *Ground Truth* a potência é próxima dos 500 W, enquanto que o algoritmo detectou potências maiores que 1000 W. Os picos em azul, que se assemelham à *microwave* ficaram com picos maiores e mais duradouros do que no *Ground Truth* do *microwave*; no dia 19 de abril às 13 horas, notam-se dois picos no *Ground Truth* em azul, enquanto que o algoritmo detectou um pico com uma potência um pouco maior, e que possui uma abrangência que começa em um pico e termina em outro; próximo às 13 horas do dia 20, o algoritmo detectou um pico de duração menor do que no *Ground Truth*, onde possui um pico mais duradouro, próximo deste. As outras previsões deveriam ser classificadas como *Unknown*, pois não se assemelham à nenhuma medição no *Ground Truth*.

Na primeira *main* da casa 6 do REDD (Figura 4.12), a mudança dos parâmetros retornou 4 eletrodomésticos. *washer_dryer*, em verde, próximo do dia 24 de maio, às 13 horas e às 13 horas do dia 22 de maio, são os dois picos detectados, ambos no período de ruído do *Ground Truth*. *freezer*, em amarelo, detectou um pico que coincide com um no *Ground Truth*, entre 1

e 13 horas do dia 24 de maio, porém, no *Ground Truth*, esta medição corresponde à *stove*. Os outros 2 não representam um eletrodoméstico do *Ground Truth* com consistência.

Na segunda *main* da casa 6 do REDD (Figura 4.13), a mudança dos parâmetros retornou 6 eletrodomésticos. Não é possível verificar quais eletrodomésticos são, pois a maioria foi coletada durante os ruídos do *Ground Truth* da casa 6.

Na casa 8 do REFIT (Figura 4.14), a mudança dos parâmetros retornou 5 eletrodomésticos. No *Ground Truth*, em roxo, vermelho e rosa aparecem, respectivamente, *television_site*, *freezer* e *computer*. Nas previsões do algoritmo, entre 2 de dezembro, de 1 às 13 horas, em roxo, azul e verde, as medições são bem próximas destas no *Ground Truth*; o azul foi rotulado como *microwave*, porém é semelhante ao *freezer* em vermelho, o roxo, que coincide com o vermelho, foi rotulado como *television_site*, e realmente coincide com o mesmo no *Ground Truth*. O verde, rotulado como *Unknown*, poderia ser rotulado como *computer*, porém, na faixa de horário mencionada, onde ele aparece, as potências estão um pouco elevadas. O vermelho foi rotulado como *freezer*, mas deveria ser rotulado como *kettle*, entre 12 de março, entre 1 e 13 horas, há uns picos que coincidem com os em verde, no *Ground Truth* (*kettle*), porém, as potências em verde no *Ground Truth* aproximam-se de 3000 W, enquanto que as preditas pelo algoritmo aproximam-se de 5000 W. O amarelo, que foi rotulado como *toaster* deveria ser rotulado como *Unknown*, porém, no começo da medição de *toaster*, entre 1 e 13 horas do dia 2 de dezembro, o gráfico se assemelha ao gráfico agregado, no mesmo período, porém, como não há correspondências no *Ground Truth*, não é possível rotulá-lo.

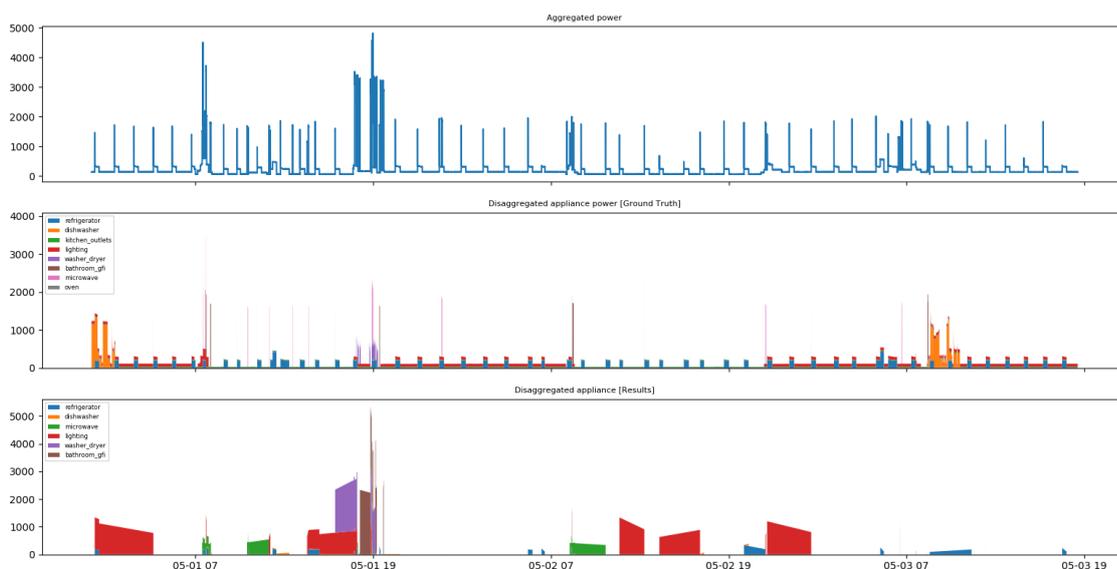


Figura 4.8: Comparação da desagregação feita com os dados da primeira *main* da casa 1 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.

As Figuras, 4.3 e 4.4, que mostram os resultados das duas *main*s da casa 2, 4.5 e 4.6,

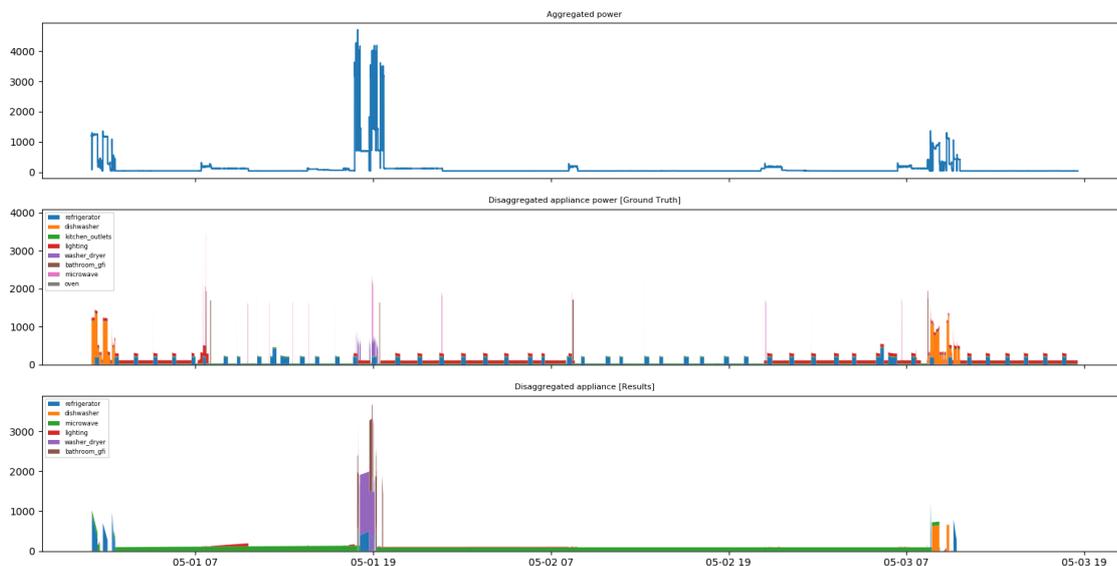


Figura 4.9: Comparação da desagregação feita com os dados da segunda *main* da casa 1 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.

que mostram os resultados das duas *mains* da casa 6; e 4.7, que mostra o resultado da casa 8 do REFIT apresentam, também, melhoras nos resultados das desagregações, porém, os parâmetros foram alterados de forma diferente. Para as casas 2 e 6, o parâmetro utilizado foi $r_i = 0,8$, e os parâmetros para a casa 8 do REFIT foram $r_i = 2,25$ e $instancelimit = 5$.

A Figura 4.15 mostra os dados de demonstração utilizados pelo algoritmo para a desagregação. Neste caso, o parâmetro alterado foi o σ , que utilizou o valor 10, ao invés de 20, como proposto no artigo. Nota-se que a desagregação neste caso foi muito próxima do ideal, talvez pela quantidade reduzida de dados, pois, neste caso, tiveram poucos eletrodomésticos rotulados como *Unknown*, e os rotulados corretamente ficaram muito próximos dos valores reais e muitos eletrodomésticos foram obtidos mais de uma vez. A Figura 4.15 é uma representação de algum desses valores que foram rotulados corretamente.

Em relação à rotulação, o procedimento seguido foi o mesmo relatado na seção 4.1.1 deste capítulo. O esperado é que a rotulação funcionasse como com os arquivos de demonstração, que leva um certo tempo, porém é um tempo não tão longo; porém, o algoritmo DTW, aplicado nos *datasets* públicos demandou mais tempo que o próprio algoritmo de desagregação. Portanto, para poupar tempo, a rotulação foi feita manualmente.

4.1.3 Avaliações

Apesar de os gráficos das séries temporais obtidas pelo algoritmo se assemelharem às do *Ground Truth*, as estatísticas relacionadas à avaliação dos resultados mostraram que o resul-

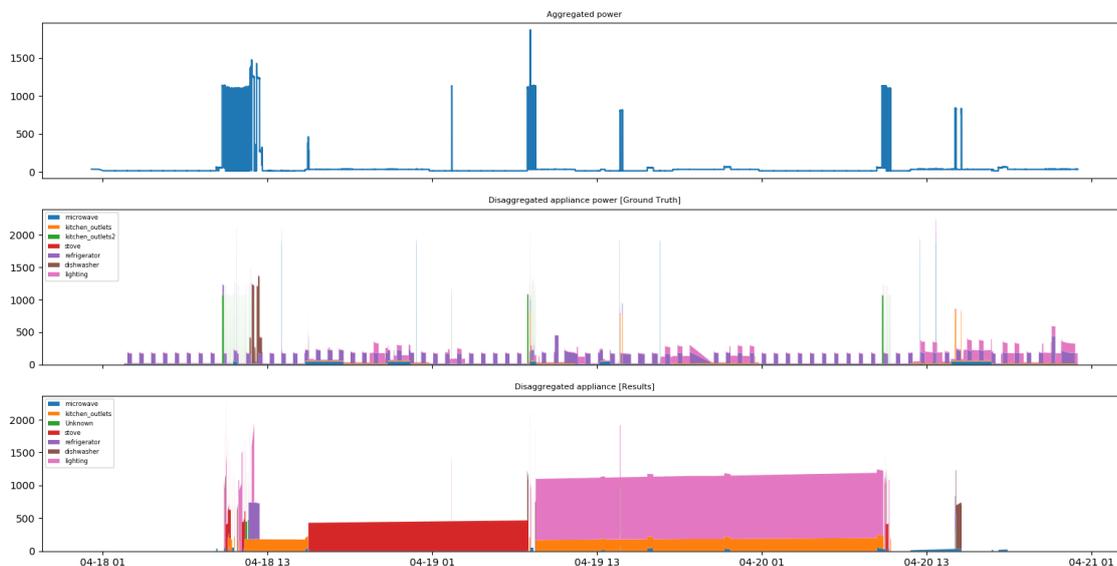


Figura 4.10: Comparação da desagregação feita com os dados da primeira *main* da casa 2 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.

tado não foi satisfatório.

Começando pelos dados de demonstração, contidos na implementação do algoritmo, no repositório do *Github*. A Tabela 4.1 mostra as métricas para tais dados. Com exceção de *kitchen_outlets1*, que deu um valor baixíssimo de verdadeiros positivos, os outros eletrodomésticos não encontraram nenhum verdadeiro positivo, mesmo que os gráficos mostrem que as séries temporais obtidas pelo algoritmo se assemelhem às do *Ground Truth*, o que fez com que os valores de Precision e Recall fossem, também, zero, e os de *f1-score* indeterminados (divisão de zero por zero, zero foi inserido na tabela por convenção). Uma explicação seria que, nesse caso, os picos foram registrados aproximadamente no dia e hora corretos, mas os dados de potência não foram os mesmos, apesar de serem aproximadamente os mesmos. Por exemplo, o primeiro pico de *refrigerator* é à meia noite e 2, do dia 23 de abril de 2011, e os valores são em média 189, 194, 175 etc. enquanto que, no mesmo dia e hora, nos resultados, os valores estão na média de 185, 183, 182 etc. Outra coisa que é possível notar é que *kitchen_outlets1*, que foi rotulado errado (ao observar a Figura 4.15, nota-se que *kitchen_outlets1* é, na verdade, *kitchen_outlets2*) foi o que deu o maior número de verdadeiros positivos, talvez sejam os valores de *kitchen_outlets1* que estão na mesma faixa de potência de *kitchen_outlets2*. Vale ressaltar que o algoritmo detectou mais de um eletrodoméstico similar ao original, e que os escolhidos para preencherem as tabelas foram os que tiveram maiores valores de avaliações corretas (verdadeiros positivos e verdadeiros negativos). Os valores de falsos positivos e falsos negativos foram iguais para todos, e foram baixos, porém, todos deram altos valores de verdadeiros negativos, e foi por isso que a acurácia do resultado foi muito alta.

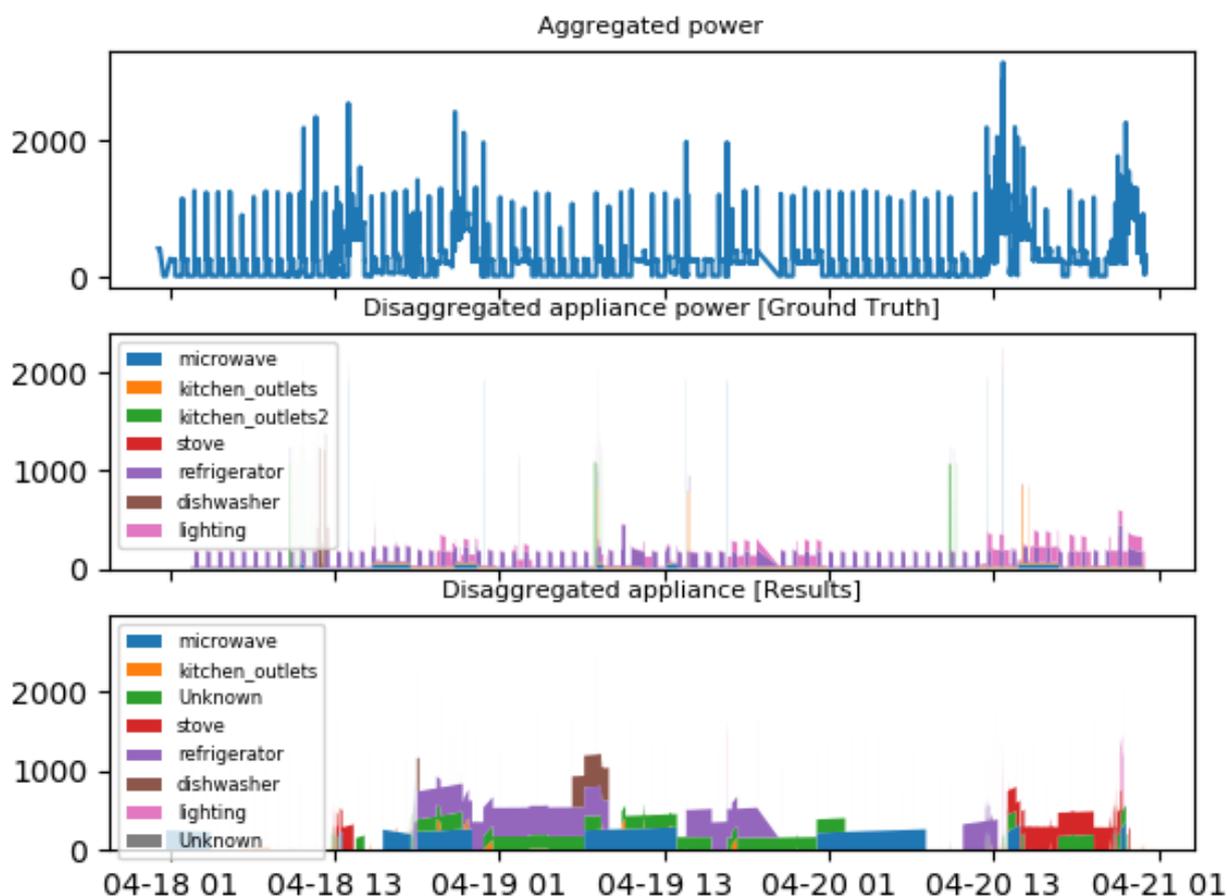


Figura 4.11: Comparação da desagregação feita com os dados da segunda *main* da casa 2 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.

Eletrrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>refrigerator</i>	0	11428	45	45	0	0	0	0,992
<i>kitchen_outlets1</i>	27	11366	63	63	0,3	0,3	0,3	0,989
<i>kitchen_outlets2</i>	0	11391	64	64	0	0	0	0,989
<i>microwave</i>	0	11392	64	64	0	0	0	0,989
<i>lighting</i>	0	11355	82	82	0	0	0	0,986

Tabela 4.1: Avaliação dos dados de demonstração.

Abaixo as avaliações para as casas do REDD e do REFIT com os parâmetros utilizados pelo artigo. Como, para os dados de demonstração, os eletrodomésticos foram rotulados pelo algoritmo na sequência onde eles aparecem no arquivo CSV do *Ground Truth*, a lógica foi a mesma para a rotulagem dos eletrodomésticos, já que o DTW demanda muito tempo com os dados do REDD e do REFIT. Os eletrodomésticos rotulados como *Unknown* foram comparados com os eletrodomésticos do *Ground Truth*, para verificar se algum eletrodoméstico foi rotulado incorretamente, e o resultado foi muito parecido com os resultados para os eletrodomésticos rotulados da

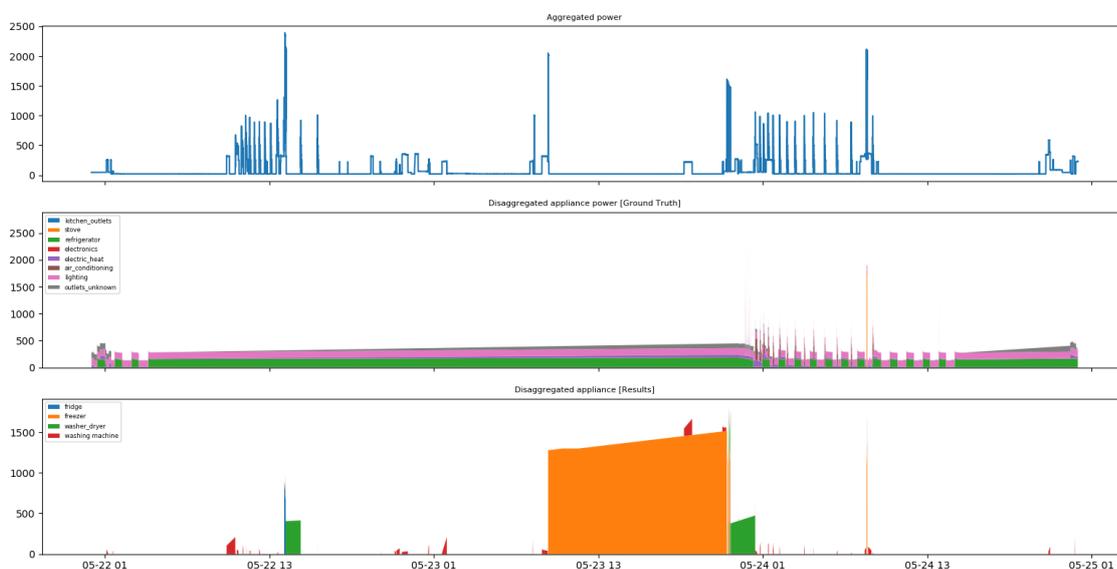


Figura 4.12: Comparação da desagregação feita com os dados da primeira *main* da casa 6 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.

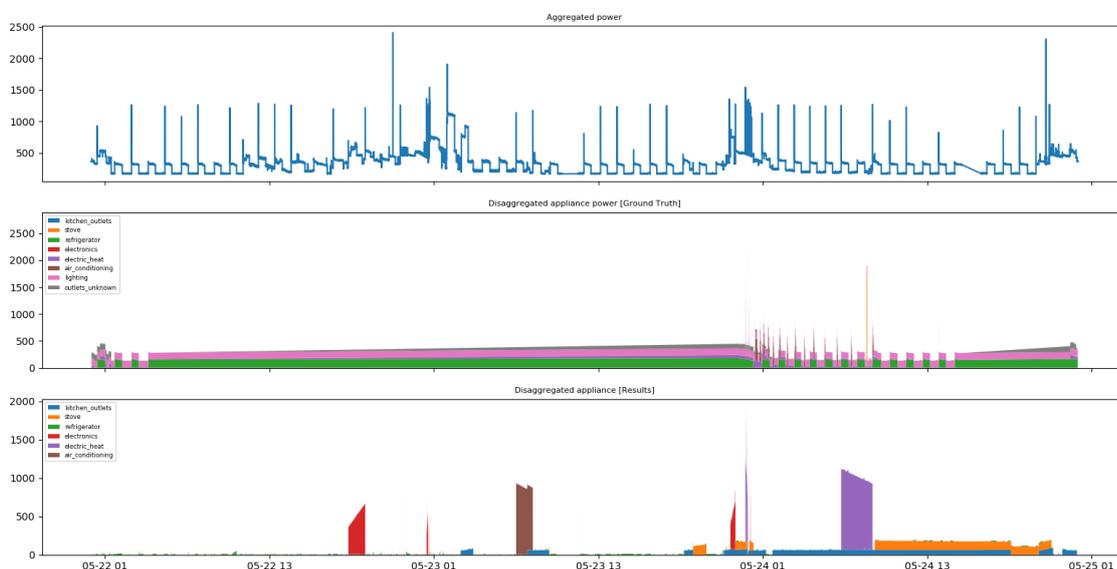


Figura 4.13: Comparação da desagregação feita com os dados da segunda *main* da casa 6 do REDD com os dados desagregados da mesma casa após a mudança nos parâmetros.

forma dita anteriormente, ou seja, o resultado de um eletrodoméstico rotulado como *Unknown* com *washer_dryer*, por exemplo, assemelhou-se muito ao resultado do que foi rotulado como *washer_dryer* no esquema mencionado anteriormente em comparação com o *washer_dryer*

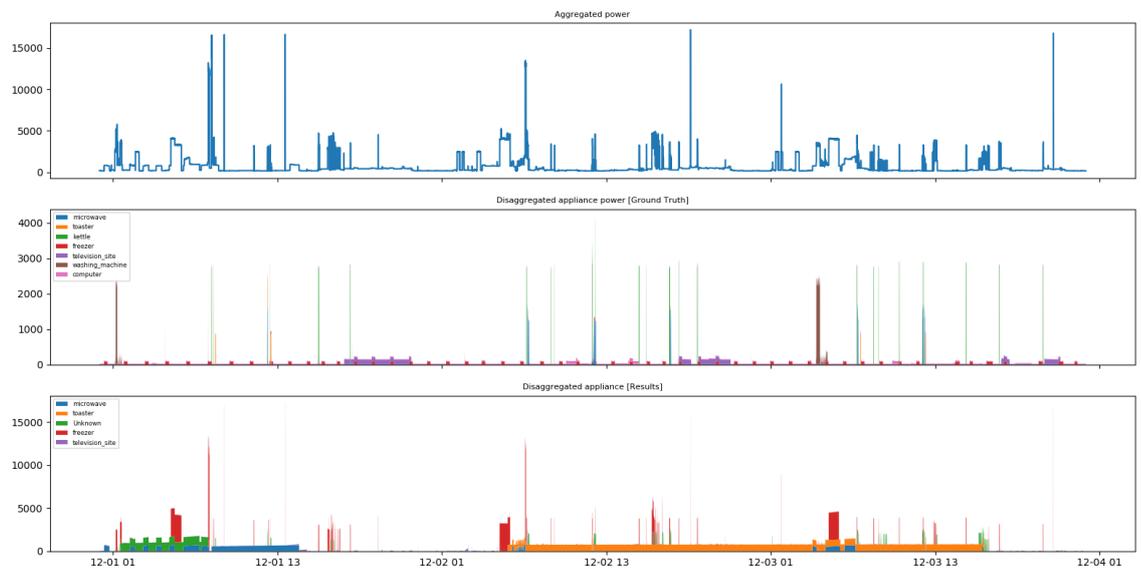


Figura 4.14: Comparação da desagregação feita com os dados da casa 8 do REFIT com os dados desagregados da mesma casa após a mudança nos parâmetros.

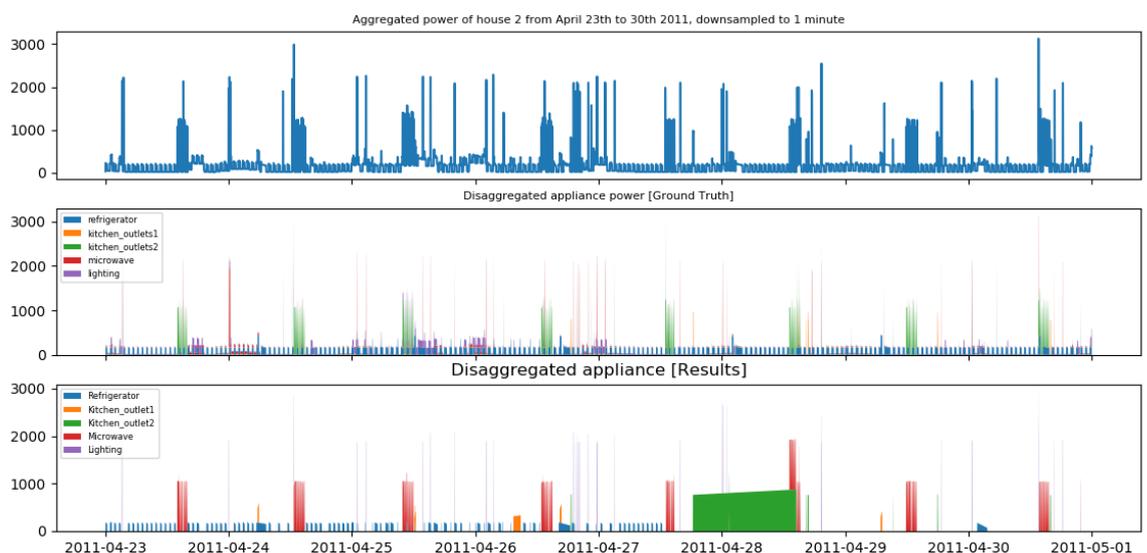


Figura 4.15: Comparação da desagregação feita com os dados de demonstração utilizados na implementação do algoritmo.

do *Ground Truth*, e o mesmo aconteceu com a comparação de *Unknown* com *refrigerator*, *kitchen_outlets*, *microwave*, entre outros. Em Zhao et al. (2016), os verdadeiros positivos (*TP*) são divididos entre *ATP* (*Accurate True Positive*) e *ITP* (*Inaccurate True Positive*), que são, respectivamente, os verdadeiros positivos que representam a rotulagem correta e incorreta do

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>bathroom_gfi</i>	15	61583	234	242	0,060	0,058	0,060	0,992
<i>dishwasher</i>	84	61944	21	25	0,8	0,771	0,784	0,999
<i>kitchen_outlets</i>	0	59296	1366	1411	0	0	0	0,955
<i>lighting</i>	45	61806	108	106	0,294	0,298	0,296	0,996
<i>microwave</i>	0	61757	155	160	0	0	0	0,995
<i>oven</i>	473	61300	140	160	0,772	0,747	0,760	0,995
<i>refrigerator</i>	0	61477	293	303	0	0	0	0,990
<i>washer_dryer</i>	145	54819	7	12	0,954	0,924	0,938	0,9997

Tabela 4.2: Avaliação dos dados da primeira *main* da casa 1 do REDD, com os parâmetros do artigo.

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>bathroom_gfi</i>	39	60839	587	608	0,062	0,060	0,062	0,981
<i>dishwasher</i>	16	61846	104	108	0,133	0,129	0,132	0,997
<i>kitchen_outlets</i>	0	59891	1073	1108	0	0	0	0,965
<i>lighting</i>	8	60045	994	1027	0,008	0,008	0,008	0,967
<i>microwave</i>	0	61553	256	254	0	0	0	0,992
<i>oven</i>	252	34233	52	109	0,829	0,698	0,758	0,995
<i>refrigerator</i>	0	61225	417	431	0	0	0	0,986
<i>washer_dryer</i>	147	61787	66	73	0,690	0,668	0,672	0,998

Tabela 4.3: Avaliação dos dados da segunda *main* da casa 1 do REDD, com os parâmetros do artigo.

eletrodoméstico. Aqui, são utilizadas as métricas convencionais, ou seja, $TP = ATP + ITP$, devido ao DTW não poder ser utilizado. O DTW foi utilizado nos dados de demonstração, mas, ainda assim, as métricas utilizadas foram as convencionais.

Na Tabela 4.2, os resultados da primeira *main* da casa 1 do REDD. O algoritmo detectou 14 eletrodomésticos, sendo 8 rotuladas como os eletrodomésticos da casa 1 do REDD, na sequência em que eles aparecem no CSV do *Ground Truth*, e as outras 6 rotuladas como *Unknown*. *washer_dryer* foi o eletrodoméstico melhor avaliado, com 93,8% de *f1-score*. *dishwasher* e *oven* vêm logo em seguida, com quase 80%. *lighting*, com quase 30% e *bathroom_gfi*, com 6% vêm logo depois. Os demais tiveram *f1-score* indeterminados (*Precision* e *Recall* iguais a zero).

Na Tabela 4.3, os resultados da segunda *main* da casa 1 do REDD. O algoritmo detectou 9 eletrodomésticos, sendo 8 rotuladas como os eletrodomésticos da casa 1 do REDD, na sequência em que eles aparecem no CSV do *Ground Truth*, e a restante rotulada como *Unknown*. Aqui, o resultado foi diferente, com *oven* como o melhor avaliado (quase 75,8%) e *washer_dryer* logo atrás (67,2%). *bathroom_gfi*, com pouco mais de 6%, *dishwasher*, com 13,2% e *lighting*, com 0,8% tiveram avaliações ruins, mas diferentes de zero. Os demais tiveram *f1-score* indeterminado.

Na Tabela 4.4, os resultados da primeira *main* da casa 2 do REDD. O algoritmo detectou

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>dishwasher</i>	362	64418	28	29	0,928	0,926	0,928	0,999
<i>kitchen_outlets1</i>	246	63658	466	466	0,346	0,346	0,346	0,986
<i>kitchen_outlets2</i>	15	63743	540	540	0,027	0,027	0,028	0,983
<i>lighting</i>	0	64006	416	416	0	0	0	0,987
<i>microwave</i>	0	63669	584	584	0	0	0	0,982
<i>refrigerator</i>	0	63665	391	391	0	0	0	0,988
<i>stove</i>	1092	60743	1501	1501	0,421	0,421	0,422	0,954

Tabela 4.4: Avaliação dos dados da primeira *main* da casa 2 do REDD, com os parâmetros do artigo.

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>dishwasher</i>	337	64445	27	27	0,923	0,923	0,926	0,999
<i>kitchen_outlets1</i>	171	63987	339	339	0,335	0,335	0,336	0,990
<i>kitchen_outlets2</i>	9	64201	313	314	0,0280	0,028	0,028	0,990
<i>lighting</i>	0	64096	370	370	0	0	0	0,989
<i>microwave</i>	0	64070	384	384	0	0	0	0,988
<i>refrigerator</i>	0	64140	348	348	0	0	0	0,989
<i>stove</i>	61	64638	69	69	0,469	0,469	0,470	0,998

Tabela 4.5: Avaliação dos dados da segunda *main* da casa 2 do REDD, com os parâmetros do artigo.

11 eletrodomésticos, sendo 7 rotuladas como os eletrodomésticos da casa 1 do REDD, na sequência em que eles aparecem no CSV do *Ground Truth*, e 4 rotuladas como *Unknown*. *dishwasher* e *stove* tiveram as melhores avaliações, com 92,8% e 42,2% respectivamente. *kitchen_outlets1* teve uma avaliação próxima de 35% e *kitchen_outlets2* teve uma avaliação próxima de 3%. Os demais tiveram *f1-score* indeterminado.

Na Tabela 4.5, os resultados da segunda *main* da casa 2 do REDD. O algoritmo detectou 9 eletrodomésticos, sendo 7 rotuladas como os eletrodomésticos da casa 1 do REDD, na sequência em que eles aparecem no CSV do *Ground Truth*, e 2 rotuladas como *Unknown*. *dishwasher* teve uma avaliação próxima de 93%, *stove* vem em segundo, com 42,2%, *kitchen_outlets* com quase 35% e *kitchen_outlets2* com 3% foram os melhores avaliados, os demais ficaram com valor indeterminado de *f1-score*.

Na Tabela 4.6, os resultados da primeira *main* da casa 6 do REDD. O algoritmo detectou 13 eletrodomésticos, sendo 8 rotuladas como os eletrodomésticos da casa 1 do REDD, na sequência em que eles aparecem no CSV do *Ground Truth*, e 5 rotuladas como *Unknown*. *outlets_unknown*, *refrigerator* e *electronics* foram os melhores avaliados, com 29,6%, 26,6% e 1,4% respectivamente, os demais, tiveram valores indeterminados de *f1-score*.

Na Tabela 4.7, os resultados da segunda *main* da casa 6 do REDD. O algoritmo detectou 11 eletrodomésticos, sendo 8 rotuladas como os eletrodomésticos da casa 1 do REDD, na sequência em que eles aparecem no CSV do *Ground Truth*, e 3 rotuladas como *Unknown*. Como na *main 1*, *outlets_unknown*, *refrigerator* e *electronics* foram os melhores avaliados,

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>air_conditioning</i>	0	21776	93	168	0	0	0	0,988
<i>electric_heat</i>	0	21827	74	135	0	0	0	0,991
<i>electronics</i>	14	20041	700	1282	0,020	0,011	0,014	0,910
<i>kitchen_outlets</i>	0	20238	639	1160	0	0	0	0,918
<i>lighting</i>	0	21630	145	262	0	0	0	0,982
<i>outlets_unknown</i>	101	21454	142	340	0,416	0,229	0,296	0,978
<i>refrigerator</i>	51	21704	86	197	0,372	0,206	0,266	0,987
<i>stove</i>	0	21204	296	537	0	0	0	0,962

Tabela 4.6: Avaliação dos dados da primeira *main* da casa 6 do REDD, com os parâmetros do artigo.

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>air_conditioning</i>	0	21740	106	191	0	0	0	0,987
<i>electric_heat</i>	0	21814	79	144	0	0	0	0,990
<i>electronics</i>	6	21167	305	559	0,019	0,011	0,014	0,961
<i>kitchen_outlets</i>	0	19189	1012	1836	0	0	0	0,871
<i>lighting</i>	0	21808	81	148	0	0	0	0,990
<i>outlets_unknown</i>	243	21381	77	337	0,759	0,419	0,54	0,981
<i>refrigerator</i>	19	21882	43	93	0,307	0,170	0,218	0,994
<i>stove</i>	0	21841	70	127	0	0	0	0,991

Tabela 4.7: Avaliação dos dados da segunda *main* da casa 6 do REDD, com os parâmetros do artigo.

mas com porcentagens diferentes, com 54%, 21,8% e 1,4% respectivamente, os demais, tiveram valores indeterminados de *f1-score*.

Na Tabela 4.8, os resultados da casa 8 do REDD. O algoritmo detectou 27 eletrodomésticos, sendo 7 rotuladas como os eletrodomésticos da casa 1 do REDD, na sequência em que eles aparecem no CSV do *Ground Truth*, e 20 rotuladas como *Unknown*. *toaster*, com 98,8%, *kettle*, com 95%, *freezer*, com 68,6%, *washing_machine*, com 60% e *television_site*, com 0,6% tiveram as melhores avaliações, e os demais, tiveram valores indeterminados de *f1-score*.

Abaixo, os resultados da desagregação com os parâmetros ajustados.

Na Tabela 4.9, os resultados da primeira *main* da casa 1 do REDD, com $r_i = 0,75$. O

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>computer</i>	0	34524	401	401	0	0	0	0,977
<i>freezer</i>	295	34761	135	135	0,686	0,686	0,686	0,992
<i>kettle</i>	95	35223	5	5	0,95	0,95	0,95	0,9997
<i>microwave</i>	0	34826	251	251	0	0	0	0,986
<i>television_site</i>	4	34134	595	595	0,007	0,007	0,006	0,966
<i>toaster</i>	612	34700	8	8	0,987	0,987	0,988	0,9996
<i>washing_machine</i>	105	35083	70	70	0,6	0,6	0,6	0,996

Tabela 4.8: Avaliação dos dados da casa 8 do REFIT, com os parâmetros do artigo.

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>bathroom_gfi</i>	15	61583	234	242	0,060	0,058	0,060	0,992
<i>dishwasher</i>	91	61993	23	26	0,798	0,778	0,788	0,999
<i>lighting</i>	17	61993	61	63	0,218	0,213	0,216	0,998
<i>microwave</i>	0	61727	170	176	0	0	0	0,994
<i>refrigerator</i>	0	61436	208	215	0	0	0	0,993
<i>washer_dryer</i>	79	61980	6	9	0,929	0,898	0,914	0,9998

Tabela 4.9: Avaliação dos dados da primeira *main* da casa 1 do REDD, com os parâmetros modificados.

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>dishwasher</i>	65	61929	38	41	0,631	0,613	0,622	0,999
<i>lighting</i>	91	21085	189	200	0,325	0,313	0,318	0,982
<i>microwave</i>	0	61909	81	83	0	0	0	0,997
<i>refrigerator</i>	0	61459	302	312	0	0	0	0,990

Tabela 4.10: Avaliação dos dados da segunda *main* da casa 1 do REDD, com os parâmetros modificados.

algoritmo detectou 6 eletrodomésticos, rotuladas na sequência em que eles aparecem no CSV do *Ground Truth*. *washer_dryer*, com 91,4%, *dishwasher*, com 78,8%, *lighting*, com 21,6% e *bathroom_gfi*, com 6% foram os melhores avaliados, e o resto, não pôde ser avaliado.

Na Tabela 4.10, os resultados da segunda *main* da casa 1 do REDD, com $r_i = 0,8$ e $instance_limit = 2$. O algoritmo detectou 4 eletrodomésticos, rotuladas na sequência em que eles aparecem no CSV do *Ground Truth*. *dishwasher*, com 62,2% e *lighting*, com 31,8%, foram os que puderam ser avaliados.

Na Tabela 4.11, os resultados da primeira *main* da casa 2 do REDD, com $r_i = 0,9$. O algoritmo detectou 7 eletrodomésticos, sendo 6 rotuladas na sequência em que eles aparecem no CSV do *Ground Truth* e uma rotulada como *Unknown*. *dishwasher*, com 93,8%, *kitchen_outlets*, com 19,8% e *stove*, com 44% foram os melhores avaliados.

Na Tabela 4.12, os resultados da segunda *main* da casa 2 do REDD, com $r_i = 0,9$. O algoritmo detectou 7 eletrodomésticos, sendo 6 rotuladas na sequência em que eles aparecem no CSV do *Ground Truth* e uma rotulada como *Unknown*. *dishwasher*, com 90%, *kitchen_outlets*,

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>dishwasher</i>	184	14464	12	12	0,939	0,939	0,938	0,998
<i>kitchen_outlets</i>	77	64138	311	311	0,199	0,199	0,198	0,990
<i>lighting</i>	0	64523	157	157	0	0	0	0,995
<i>microwave</i>	0	64042	398	398	0	0	0	0,988
<i>refrigerator</i>	0	64117	360	360	0	0	0	0,989
<i>stove</i>	344	63619	437	437	0,441	0,441	0,440	0,981

Tabela 4.11: Avaliação dos dados da primeira *main* da casa 2 do REDD, com os parâmetros modificados.

Eletrrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>dishwasher</i>	304	64465	34	34	0,899	0,899	0,9	0,999
<i>kitchen_outlets</i>	33	64701	51	51	0,393	0,393	0,392	0,998
<i>lighting</i>	0	64467	185	185	0	0	0	0,994
<i>microwave</i>	0	64344	246	247	0	0	0	0,992
<i>refrigerator</i>	0	64214	312	312	0	0	0	0,990
<i>stove</i>	413	63449	487	488	0,459	0,458	0,460	0,985

Tabela 4.12: Avaliação dos dados da segunda *main* da casa 2 do REDD, com os parâmetros modificados.

Eletrrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>electronics</i>	2	21806	81	148	0,0241	0,013	0,018	0,990
<i>kitchen_outlets</i>	0	16341	2024	3673	0	0	0	0,742
<i>refrigerator</i>	28	21849	49	111	0,364	0,201	0,260	0,993
<i>stove</i>	0	21367	238	432	0	0	0	0,970

Tabela 4.13: Avaliação dos dados da primeira *main* da casa 6 do REDD, com os parâmetros modificados.

com 39,2% e *stove*, com 46% foram os melhores avaliados.

Na Tabela 4.13, os resultados da primeira *main* da casa 6 do REDD, com $r_i = 0,9$. O algoritmo detectou 4 eletrodomésticos, rotuladas na sequência em que eles aparecem no CSV do *Ground Truth*. *refrigerator*, com 26% e *electronics*, com 1,8% foram os melhores avaliados.

Na Tabela 4.14, os resultados da segunda *main* da casa 6 do REDD, com $r_i = 0,9$. O algoritmo detectou 6 eletrodomésticos, rotuladas na sequência em que eles aparecem no CSV do *Ground Truth*. *refrigerator*, com 21% e *electronics*, com 1,4% foram os melhores avaliados.

Na Tabela 4.15, os resultados da casa 8 do REFIT, com $r_i = 2,25$ e *instance_limit* = 5. O algoritmo detectou 5 eletrodomésticos, rotuladas na sequência em que eles aparecem no CSV do *Ground Truth* e um com *Unknown*. *freezer*, com 75% e *toaster*, com 51,6% foram os melhores avaliados.

Eletrrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>air_conditioning</i>	0	21740	106	191	0	0	0	0,987
<i>electric_heat</i>	0	21951	30	55	0	0	0	0,996
<i>electronics</i>	5	21344	243	445	0,020	0,011	0,014	0,969
<i>kitchen_outlets</i>	0	20670	486	881	0	0	0	0,938
<i>refrigerator</i>	19	21875	45	98	0,297	0,162	0,210	0,994
<i>stove</i>	0	21448	209	380	0	0	0	0,973

Tabela 4.14: Avaliação dos dados da segunda *main* da casa 6 do REDD, com os parâmetros modificados.

Eletrodoméstico	TP	TN	FP	FN	Pr	Re	F1	Acc
<i>freezer</i>	36	35267	12	12	0,75	0,75	0,75	0,999
<i>microwave</i>	0	35183	72	72	0	0	0	0,996
<i>television_site</i>	0	35090	118	118	0	0	0	0,993
<i>toaster</i>	167	34846	157	157	0,515	0,515	0,516	0,991

Tabela 4.15: Avaliação dos dados da casa 8 do REFIT, com os parâmetros modificados.

Comparações com o artigo

Na casa 1 do REDD, *washer_dryer*, *oven*, *lighting*, *dishwasher* e *bathroom_gfi* foram os melhor avaliados pela implementação do algoritmo, em ambas as *mains*, com a diferença de que na segunda *main* o resultado foi pior, portanto, as comparações a seguir serão feitas com a primeira *main*. O artigo mostra que o eletrodoméstico melhor avaliado foi *refrigerator*, com 84% de *f1-score*, enquanto que *dishwasher* foi o pior, com 38%. Isso é explicado pelo artigo que *dishwasher* e *refrigerator* têm uma faixa de potência parecidas e, portanto, *dishwasher* foi classificado erroneamente como *refrigerator*. Na implementação do algoritmo, *dishwasher* foi o segundo melhor, com 78,4%, enquanto que *refrigerator* sequer foi avaliado. *washer_dryer* foi o segundo melhor na avaliação do artigo, com 76%, enquanto que na implementação do algoritmo, *washer_dryer* foi o melhor avaliado, com 93,8%. *oven* teve 64% no artigo, enquanto que na implementação, teve 76%. *lighting* teve 49% no artigo, na implementação, 29,6%. *bathroom_gfi* teve 72% no artigo, na implementação, 6%, sendo, portanto, o pior dos que conseguiram ser avaliados.

Na casa 2 do REDD, *dishwasher*, *kitchen_outlets1*, *kitchen_outlets2* e *stove* foram os melhores avaliados pela implementação do algoritmo, em ambas as *mains* as porcentagens foram quase iguais. No artigo, *microwave* foi o melhor avaliado, com 94% de *f1-score*, enquanto que na implementação, ele sequer foi avaliado. *dishwasher* foi o melhor avaliado pela implementação do algoritmo, com 92,8%, enquanto que no artigo, foi o segundo pior, com 49%. *stove* foi o segundo melhor pela implementação do algoritmo, com 42,2%, enquanto que, no artigo, foi o pior, com 44%. *kitchen_outlets1* foi o terceiro melhor na implementação, com 34,6%, enquanto que no artigo, foi um dos melhores, com 85%. *kitchen_outlets1* foi o pior, com 2,8%, na implementação, no artigo, também foi um dos melhores, com 85%.

Na casa 6, 3 eletrodomésticos tiveram a melhor avaliação, *outlets_unknown*, *refrigerator* e *electronics*. No artigo, de novo, *microwave* foi o melhor nessa residência, com 87%, enquanto que na implementação do algoritmo, sequer foi avaliado. O melhor na implementação foi *outlets_unknown*, com 29,6% na primeira *main*, e 54% na segunda *main*, enquanto que, no artigo, teve 69%. *refrigerator* teve 26,6% na implementação, enquanto que no artigo, teve 82%. *electronics* teve 1,4% na implementação, no artigo, 42%. No artigo, a casa 6 teve um desempenho muito baixo, devido ao *Ground Truth* da casa 6 ter muitos ruídos. Na implementação do algoritmo isso foi muito refletido.

Na casa 8 do REFIT, apenas *computer* e *microwave* não foram avaliados. *refrigerator*

teve 95% no artigo, porém a base de dados do REFIT não possui *refrigerator*, portanto, não é possível saber de onde foi retirado esse eletrodoméstico, e aqui, foi desconsiderado. *toaster* foi o melhor avaliado na implementação, com 98,8%, no artigo, 67%. *kettle* teve 95% na implementação, sendo, portanto, o segundo melhor avaliado, no artigo teve 84%. *washing_machine* teve 60% na implementação, no artigo, 40%. *freezer* teve 68,6% na implementação, no artigo, 32%. *television_site* foi o pior, com 6% na implementação, no artigo, 4%.

Comparações com a mudança dos parâmetros

Com a mudança dos parâmetros utilizados pelo artigo, mostrada na subseção 4.1.3, o resultado é mostrado abaixo.

Na primeira *main* da casa 1 do REDD, *washer_dryer*, *lighting*, *dishwasher* e *bathroom_gfi* foram os melhores avaliados, como no desempenho com os parâmetros utilizados no artigo, com a diferença que *oven* não foi avaliado. *washer_dryer* continuou sendo o melhor, com 91,4%, *dishwasher* teve 78,8%, *lighting* teve 21,6% e *bathroom_gfi*, 6%. Portanto, em relação à execução do algoritmo com os parâmetros utilizados pelo algoritmo, o desempenho não mudou muito, pelo menos em relação à primeira *main*. Na segunda *main*, *dishwasher* e *lighting* foram avaliados, com a mudança dos parâmetros. *lighting* teve 31,8% e *dishwasher* teve 62,2%. Aqui, *dishwasher* melhorou, de 13,2% subiu para 62,2%, *lighting*, de 0,8%, teve 31,8%.

Na primeira *main* da casa 2, *dishwasher*, *kitchen_outlets1* e *stove*, com a diferença que *kitchen_outlets2* não foi avaliado. *dishwasher* teve 93,8%, contra 92,8% da primeira execução. *kitchen_outlets1* teve 19,8%, contra 34,6%. *stove* teve 44%, contra 42,2%. Portanto, tirando *kitchen_outlets1*, que teve uma piora, nos outros, a mudança não foi tão grande. Na segunda *main*, as mesmas residências foram classificadas. *dishwasher* teve 90%, contra 92,6% da primeira execução. *kitchen_outlets1* teve 39,2%, contra 33,6%. *stove* teve 46%, contra 47%.

Na primeira *main* da casa 6, *refrigerator*, com 21%, contra 26,6% e *electronics*, com 1,4%, tendo o mesmo resultado na primeira implementação. *outlets_unknown* não foi avaliado com a mudança dos parâmetros. Na segunda *main*, *refrigerator*, com 21%, contra 21,8% e *electronics*, com 1,4%, tendo o mesmo resultado na primeira implementação. Portanto, as duas *main*s tiveram os mesmos resultados.

Na casa 8 do REFIT, *freezer*, com 75%, contra 68,6%, e *toaster*, com 51,6%, contra 98,8% foram avaliados.

5

Considerações Finais

O NILM (*Non-intrusive Load Monitoring*) é uma área importante, que integra *hardware* e *software* com o intuito de monitorar a energia elétrica e tirar informações importantes deste monitoramento, inclusive com o intuito de melhorar o aproveitamento do consumo de energia de uma determinada residência. A desagregação de energia é parte importante desse processo, separando da energia total utilizada pela casa os eletrodomésticos que utilizam uma porção da energia em determinado tempo.

Diversos algoritmos foram propostos ao longo dos anos, a maioria necessita de treinamento da base de dados, porém, o algoritmo proposto por esse trabalho não utiliza treinamento, e sim, GSP (*Graph Signal Processing*), que cria um grafo a partir de processamento de sinais e, de acordo com a semelhança dos vértices, os eletrodomésticos são separados e, posteriormente, rotulados, utilizando um algoritmo chamado DTW (*Dynamic Time Warping*), comparando eletrodomésticos já rotulados com os obtidos pelo algoritmo.

A implementação do algoritmo feita em https://github.com/loneharoon/GSP_energy_disaggregator.git consegue fazer a desagregação com uma eficiência maior com os dados de demonstração fornecidos pelo próprio programador, porém, com os datasets públicos, a desagregação não teve a mesma eficiência. Alguns parâmetros são utilizados pelo algoritmo como forma de selecionar melhor os dados que serão utilizados, alguns são estatísticos, entre outros, e alterando esses parâmetros, notou-se, observando os gráficos, que a eficiência da desagregação dos *datasets* públicos teve uma mudança significativa. Porém, o cálculo das métricas mostrou que o desempenho foi praticamente igual com e sem a mudança dos parâmetros; o que mudou foi que o algoritmo, com a mudança dos parâmetros, detectou menos eletrodomésticos que com os parâmetros utilizados pelo artigo. Isso pode ser uma vantagem, pois haverá mais chance de não ter eletrodomésticos rotulados como *Unknown*, mas teve como desvantagem detectar menos eletrodomésticos do que os que estão registrados no *Ground Truth*. Então, apesar de os gráficos mostrarem que o algoritmo fez a desagregação bem próxima do original,

as métricas mostraram que os gráficos estão um pouco distantes do original. Após a obtenção dos novos eletrodomésticos, estes foram rotulados manualmente, seguindo a orientação do artigo que propôs o algoritmo, porém, sem utilizar o algoritmo DTW, pois demanda muito tempo.

Trabalhos futuros envolvem melhorar a acurácia do algoritmo para que ele possa desagregar energia de qualquer dataset (e investigar o motivo de a desagregação ter funcionado tão bem com os dados de demonstração, que possuem bem menos dados, e ter funcionado razoavelmente com os dados dos *datasets* públicos, que possuem mais dados), tornar eficiente o algoritmo para a rotulação dos eletrodomésticos (sem utilizar treinamento, como proposto pelo algoritmo) e criar algo similar ao NILMTK (Batra et al., 2014), porém com algoritmos que não necessitem de treinamento.

Referências bibliográficas

- Hana Altrabalsi, Jing Liao, Lina Stankovic, and Vladimir Stankovic. A low-complexity energy disaggregation method: Performance and robustness. 4(1):884–905, 2016.
- Nipun Batra, Jack Kelly, Oliver Parson, and Haimonti Dutta. Nilmtk: An open source toolkit for non-intrusive load monitoring. 2014.
- Anthony Faustine, Nerey Mvungi, Shubi Kaijage, and Kisangiri Michael. A survey on non-intrusive load monitoring methodologies and techniques for energy disaggregation problem. 12 2017.
- George Hart. Nonintrusive appliance load monitoring. 80(12):1870–1891, 1992.
- Kanghang He, , Lina Stankovic, Jing Liao, and Vladimir Stankovic. Non-intrusive load disaggregation using graph signal processing. pages 1739 – 1747, 2016.
- Jack Kelly and William Knottenbelt. Neural nilm: Deep neural networks applied to energy disaggregation. 2015. DOI [10.1145/2821650.2821672](https://doi.org/10.1145/2821650.2821672).
- Hyungsul Kim, Manish Marwah, Martin Arlitt, Geoff Lyon, and Jiawei Han. Unsupervised disaggregation of low frequency power measurements. pages 747–758, 2011.
- J Kolter and Matthew Johnson. Redd: A public data set forenergy disaggregation research. 2011.
- Jing Liao, Georgia Elafoudi, Lina Stankovic, and Vladimir Stankovic. Power disaggregation for low-sampling rate data. 2014.
- David Murray, Jing Liao, Lina Stankovic, Vladimir Stankovic, Richard Hauxwell-Baldwin, Charlie Wilson, Michael Coleman, Tom Kane, and Steven Firth. *A data management platform for personalised real-time energy feedback*. 2015.
- Randy Quindai, Bruno Barbosa, Charles Almeida, Heitor Ramos, Joel Rodrigues, and André Aquino. A non-intrusive low-cost kit for electric power measuring and energy disaggregation. *JOURNAL OF COMMUNICATIONS SOFTWARE AND SYSTEMS*, 14(1):9–17, 2017.

- Aliaksei Sandryhaila and Jose M. F. Moura. Classification via regularization on graphs. pages 495–498, 2013a.
- Aliaksei Sandryhaila and Jose M. F. Moura. Discrete signal processing on graphs. 61: 1644–1656, 2013b.
- Aliaksei Sandryhaila and Jose M. F. Moura. Big data analysis with signal processing on graphs: Representation and processing of massive data sets with irregular structure. pages 80–90, 2014.
- David I Shuman, Sunil K. Narang, Pascal Frossard, Antonio Ortega, and Pierre Vandergheynst. The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains. pages 83–98, 2013.
- Vladimir Stankovic, Jing Liao, and Lina Stankovic. A graph-based signal processing approach for low-rate energy disaggregation. *2014 IEEE Symposium on Computational Intelligence for Engineering Solutions (CIES)*, pages 81–87, 2014.
- Wikipedia. Precision and recall. URL https://en.wikipedia.org/wiki/Precision_and_recall.
- Benjamin Wild, Karim S. Barsim, and Bin Yang. A low-complexity energy disaggregation method: Performance and robustness. pages 73–77, 2015.
- Bochao Zhao, Lina Stankovic, and Vladimir Stankovic. Blind non-intrusive appliance load monitoring using graph-based signal processing. 2015. URL <https://doi.org/10.1109/GlobalSIP.2015.7418158>.
- Bochao Zhao, Lina Stankovic, and Vladimir Stankovic. On a training-less solution for non-intrusive appliance load monitoring using graph signal processing. 4:1784–1799, 03 2016.