

UNIVERSIDADE FEDERAL FLUMINENSE

IGOR DA PENHA NATAL

**MOut-HAR: Um Modelo Minimalista de
Reconhecimento de Atividades Humanas para
Ambientes Fora de Casa**

NITERÓI

2020

UNIVERSIDADE FEDERAL FLUMINENSE

IGOR DA PENHA NATAL

**MOut-HAR: Um Modelo Minimalista de
Reconhecimento de Atividades Humanas para
Ambientes Fora de Casa**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para a obtenção do Grau de Doutor em Computação. Área de concentração: Engenharia de Sistemas e Informação.

Orientador:

Leandro Augusto Frata Fernandes

Co-orientadora:

Ana Cristina Bicharra Garcia

NITERÓI

2020

Ficha catalográfica automática - SDC/BEE
Gerada com informações fornecidas pelo autor

N271m Natal, Igor da Penha
MOut-HAR: Um Modelo Minimalista de Reconhecimento de
Atividades Humanas para Ambientes Fora de Casa / Igor da
Penha Natal ; Leandro Augusto Frata Fernandes, orientador ;
Ana Cristina Bicharra Garcia, coorientadora. Niterói, 2020.
78 f. : il.

Tese (doutorado)-Universidade Federal Fluminense, Niterói,
2020.

DOI: <http://dx.doi.org/10.22409/PGC.2020.d.98786814249>

1. GPS. 2. Perfil do usuário. 3. Aprendizado de máquina.
4. Produção intelectual. I. Fernandes, Leandro Augusto
Frata, orientador. II. Garcia, Ana Cristina Bicharra,
coorientadora. III. Universidade Federal Fluminense. Instituto
de Computação. IV. Título.

CDD -

IGOR DA PENHA NATAL

MOut-HAR: Um Modelo Minimalista de Reconhecimento de Atividades Humanas para
Ambientes Fora de Casa


Tese de Doutorado apresentada ao Programa
de Pós-Graduação em Computação da Uni-
versidade Federal Fluminense como requisito
parcial para a obtenção do Grau de Dou-
tor em Computação. Área de concentração:
Engenharia de Sistemas e Informação.

Aprovada em Abril de 2020.

BANCA EXAMINADORA




Prof^o. LEANDRO AUGUSTO FRATA FERNANDES - Orientador, UFF



Prof^a. ANA CRISTINA BICHARRA GARCIA, Co-orientadora, UNIRIO



Prof^a. FLAVIA CRISTINA BERNARDINI, UFF



Prof^o. JOSÉ VITERBO FILHO, UFF



Prof^o. LUÍS MIGUEL PARREIRA E CORREIA, ULisboa



Prof^o. JOSÉ MANUEL MOLINA LÓPEZ, UC3M

Niterói

2020

Dedico este trabalho a Deus, à minha família e a minha namorada Adriana.

Agradecimentos

Agradeço a Deus por me proteger e me iluminar em todos os meus caminhos e a todos que direta ou indiretamente me ajudaram durante essa jornada, em especial ao meus orientadores Leandro A. F. Fernandes, Ana Cristina Bicharra Garcia e Luís Correia por todos ensinamentos durante essa trajetória.

Agradeço aos meus pais e minha irmã, por sempre me apoiarem e incentivarem nessa caminhada e em todas as outras jornadas. Agradeço à minha namorada Adriana Amaral pelo apoio e pela paciência durante o caminho.

Muito obrigado aos professores e técnicos que sempre foram solícitos para as dúvidas e os ensinamentos. Agradeço também aos amigos e colegas de disciplina conquistados nessa longa caminhada, em especial, aos amigos André Saraiva e Marcus Souza.

Finalmente, agradeço a CAPES pelo apoio financeiro durante o doutorado e doutorado sanduíche.

Resumo

Os *smartphones* se tornaram um dispositivo indispensável para as pessoas devido às suas crescentes funcionalidades e preços mais acessíveis para a população em geral. Seus sensores incorporados, incluindo o *Global Position System* - GPS, o acelerômetro e o giroscópio, abriram oportunidades para apoiar diversas tarefas na rotina das pessoas. Uma das tarefas que utilizam esses sensores é a de reconhecimento de atividade humana (*Human Activity Recognition* - HAR), tanto em ambientes internos quanto em ambientes externos. Neste trabalho é apresentado um modelo minimalista de HAR para ambientes fora de casa (MOut-HAR), a abordagem contempla desde a coleta de dados até a concepção de um reconhecedor de atividades. O minimalismo proposto está diretamente ligado ao número de sensores utilizados, no caso apenas o GPS, e ao número de atributos utilizados. Os dados de GPS foram enriquecidos com o conhecimento semântico gerando o atributo de Ponto de Interesse (*Point of Interest* - POI) e complementados com poucas informações do perfil do usuário. A coleta de dados foi guiada através de uma ontologia baseada no conhecimento prévio do estado da arte e através de um aplicativo para *smartphones Android*. Foram coletados dados de voluntários dos estados do Rio de Janeiro e Minas Gerais, gerando um *dataset* chamado HAR-Brazilian dividido em dois subconjuntos. O modelo desenvolvido tem como objetivo reconhecer 13 atividades distintas, incluindo 3 atividades de deslocamento e 10 estacionárias. O modelo foi avaliado através de acurácia, *recall*, precisão e *F-Score*, e apresentou resultados semelhantes ou melhores que o estado da arte. Os resultados demonstram que uma combinação adequada de informações, mesmo que sejam simples, podem produzir uma solução eficiente para a tarefa de HAR em ambientes fora de casa.

Palavras-chave: reconhecimento de atividade humana, dados sensoriais enriquecidos, informações semânticas, perfil do usuário, aprendizado de máquina.

Abstract

The smartphones have become an indispensable device for people due to their growing features and more affordable prices for the general population. Their embedded sensors including the Global Position System - GPS, the accelerometer and the gyroscope, have opened opportunities to support diverse tasks in people's routines. One of the tasks that use these sensors is to Human Activity Recognition (HAR), both indoors and outdoors. In this work it is presented a minimalist out-of-home HAR (MOut-HAR) model, the approach includes everything from data collection to the design of an activity recognizer. The proposed minimalism is directly linked to the number of sensors used, in this case only the GPS, and the number of attributes used. The GPS data was enriched with semantic knowledge, generating the Point of Interest (POI) attribute and complemented with little information from the user's profile. The data collection was guided through an ontology-based on prior knowledge of the state of the art and an application for Android smartphones. Data were collected from volunteers from the states of Rio de Janeiro and Minas Gerais, generating a dataset called HAR-Brazilian divided into two subsets. The developed model aims to recognize 13 different activities, including 3 moving and 10 stationary activities. The model was evaluated through accuracy, recall, precision, and F-Score, and presented results similar or better than the state of the art. The results show that an appropriate combination of information, even if it is simple, can produce an efficient solution to the task of HAR in environments out-of-home.

Keywords: human activity recognition, enriched sensor data, semantic informations, user profile, machine learning.

Lista de Figuras

2.1	Exemplos de atividades compostas, sequenciais, simultâneas e intercaladas.	12
4.1	Fluxograma do Modelo MOut-HAR. A fase de geração do modelo está acima da fase de execução.	24
4.2	Fluxograma do Modelo <i>Waterfall</i> . As caixas coloridas em azul e amarelo representam os processos utilizados pelo nosso modelo. As caixas azuis representam os processos que usam a mesma abordagem e as caixa amarelas representam os processos com diferentes abordagens.	25
4.3	Exemplo de POIs localizados em um mapa. Essa imagem foi obtida do <i>Google Places</i> usando o <i>Point of Interest Auto Map</i> ¹	29
5.1	Ontologia para o reconhecimento de atividades fora de casa.	37
5.2	Interface do aplicativo desenvolvido para coleta de dados.	38
6.1	Experimento de sensibilidade dos atributos pela técnica <i>Correlation based Feature Selection</i> com atividades estáticas.	44
6.2	Experimento de sensibilidade dos atributos pela técnica <i>Correlation based Feature Selection</i> com todas as atividades.	45
6.3	Experimento de sensibilidade dos atributos pela técnica <i>Information Gain Based Feature Selection</i> com atividades estáticas.	46
6.4	Experimento de sensibilidade dos atributos pela técnica <i>Information Gain Based Feature Selection</i> com todas as atividades.	46
6.5	Experimento de sensibilidade dos atributos pela técnica <i>Relief</i> com atividades estáticas.	47
6.6	Experimento de sensibilidade dos atributos pela técnica <i>Relief</i> com todas as atividades.	47

Lista de Tabelas

2.1	Tipos de atividades encontrados na literatura.	12
4.1	Consumo energético sensorial e perda de informação em intervalos de tempo diferentes.	27
4.2	Discretização dos atributos de GPS e do relógio	27
4.3	Relação entre o tipo de POI de acordo com o <i>Google Places</i> e as categorias de POI.	30
4.4	Relação entre a categoria do POI e as atividades observadas no HAR-BRAZILIAN-MG Dataset	30
4.5	Valores dos atributos semânticos.	32
5.1	Atributos e características dos dados do <i>Weeplaces</i>	35
5.2	Atividades reconhecidas nesta tese.	39
5.3	Distribuição do perfil dos voluntários do <i>dataset</i> HAR-Brazilian-RJ.	39
5.4	Distribuição de instâncias das atividades no <i>dataset</i> HAR-Brazilian-RJ.	40
5.5	Distribuição do perfil dos voluntários do <i>dataset</i> HAR-Brazilian-MG.	40
5.6	Distribuição de instâncias das atividades no <i>dataset</i> HAR-Brazilian-MG.	41
5.7	Exemplos (três exemplos) de instâncias do <i>HAR-Brazilian</i>	41
6.1	Resultados do teste usando apenas os atributos básicos e perfil do usuário.	48
6.2	Resultados do teste usando apenas os atributos básicos e atributos do GPS.	49
6.3	Resultados do teste usando todos os atributos.	49
6.4	Resultados treinando com o <i>dataset</i> HAR-Brazilian-MG e testando com o HAR-Brazilian-RJ.	50
6.5	Distribuição de instâncias das atividades no <i>dataset</i> Weeplaces.	51
6.6	Resultados treinando com nosso <i>dataset</i> e testando com o <i>Weeplaces</i>	51

- 7.1 Sumarização dos trabalhos relacionados. TR: Trabalhos relacionados, NV: Número de voluntários, DE: Duração do experimento (d=dias, mo=meses), TI: Intervalo de tempo entre os pontos de coleta de dados (em segundos, exceto [28] a cada 10 metros), NI: Número de instâncias, SI: Sensores usados para coletar informações, AS: Quantidade de atributos semânticos, NA: Número de atividades, e Resultados: A=acurácia, R=*recall*, P=precisão. 54

Lista de Abreviaturas e Siglas

GPS	:	<i>Global Positioning System;</i>
HAR	:	<i>Human Activity Recognition;</i>
KNN	:	<i>K-Nearest Neighbors;</i>
MLP	:	<i>Multilayer Perceptron;</i>
NB	:	<i>Naive Bayes;</i>
POI	:	<i>Point of Interest;</i>
RF	:	<i>Random Forest;</i>
SVM	:	<i>Support Vector Machine;</i>

Sumário

1	Introdução	1
1.1	Ideia Central	5
1.2	Objetivos e Metodologia	6
1.3	Contribuições	6
1.4	Organização	7
1.5	Artigos Publicados	7
2	Sensores e Tarefa de Reconhecimento de Atividades	9
2.1	Sensores	9
2.2	Tarefa de Reconhecimento de Atividades	11
2.3	Discussão	15
3	Trabalhos Relacionados	17
3.1	GPS em HAR	17
3.2	Seleção de atributos e ontologias para HAR	20
3.3	Discussão	22
4	Modelo MOut-HAR	23
4.1	Sensoriamento	25
4.2	Processamento de Sinais	27
4.3	Extração de <i>Features</i> e Perfil do Usuário	28
4.4	Geração do Classificador de HAR e Classificador de HAR	31
4.5	Discussão	32

5	HAR-Brazilian Dataset	34
5.1	Ontologia	36
5.2	Metodologia de Coleta de Dados	37
5.3	HAR-Brazilian-RJ Dataset	38
5.4	HAR-Brazilian-MG Dataset	39
5.5	Discussão	41
6	Experimentos e Análise dos Resultados	42
6.1	Métodos de Análise	42
6.2	Experimento de Sensibilidade	43
6.3	Experimento dos Atributos	47
6.4	Experimento com o Dataset HAR-Brazilian-RJ	49
6.5	Experimento com o Dataset Weeplaces	50
6.6	Discussão	51
7	Conclusões e Trabalhos Futuros	53
7.1	Contribuições da Pesquisa	54
7.1.1	Minimalismo no Uso de Atributos	54
7.1.2	Satisfação Quanto ao Consumo Energético	55
7.1.3	Abrangência do Modelo	55
7.1.4	Escalabilidade	56
7.2	Limitações	56
7.3	Trabalhos Futuros	57
	Referências	58

Capítulo 1

Introdução

Em nossas rotinas, procuramos tentar entender o comportamento das pessoas ao nosso redor e através dele descobrir quais atividades estão sendo realizadas. Em casa, temos a curiosidade de saber se nossos familiares estão trabalhando, estudando, ou almoçando, por exemplo. Essa capacidade de reconhecimento de atividades parece tão natural e simples para qualquer pessoa comum, mas quando se trata de um computador, o processo exige funções complicadas para sensoriamento, aprendizado e inferência. Vamos pensar, por exemplo, como reconhecer a atividade "almoçando", talvez vendo uma pessoa em um restaurante no horário de almoço. A partir de tais evidências, poderíamos inferir a atividade com base em nossas experiências passadas. Todas essas funções de detectar os ambientes, aprender com as experiências passadas e aplicar conhecimento para inferência ainda são grandes desafios para os computadores modernos. Se eventualmente forem desenvolvidos modelos e sistemas que possam reconhecer as várias atividades das pessoas de maneira confiável, pode ser melhorada a maneira como as pessoas interagem com os computadores, haverá um enorme impacto no comportamento, nas ciências sociais e cognitivas.

A evolução dos celulares fez com que eles se tornassem um dispositivo indispensável para as pessoas, o crescimento das funções e a diminuição do preço foram pontos culminantes para que fosse possível tamanha disseminação. Os celulares evoluíram, podendo executar praticamente todas as tarefas de um computador (e.g., acesso a internet, leitura e escrita de emails, redação de textos, jogos, etc.) em virtude do seu alto poder de processamento e capacidade de armazenamento, e por isso, foram rebatizados como *smartphones*. Segundo a Fundação Getúlio Vargas - FGV [32], em maio de 2019 haviam 230 milhões de *smartphones* em uso no Brasil, ou seja, mais de um dispositivo por habitante.

Outro aspecto relacionado aos *smartphones* é a quantidade de informações que eles

conseguem capturar do usuário através de aplicativos e sensores embutidos na sua arquitetura. Os dispositivos mais modernos contam com sensores de rastreamento de movimento (e.g., *Global Positioning System* - GPS, acelerômetro, giroscópio e magnetômetro), ambiental (e.g., umidade, temperatura, luminosidade), de interface (e.g., *touchscreen* e reconhecimento de gesto), entre outros. Os sensores possibilitam extrair informações que podem ser usadas em uma quantidade virtualmente ilimitada de aplicações, como gerenciamento de tempo pessoal, monitoramento comportamental, identificação de perigos, planejamento urbano, suporte à tecnologia de assistência médica e reconhecimento de atividades [12, 28, 56, 68].

A área de Reconhecimento de Atividade Humanas (*Human Activity Recognition* - HAR) visa reconhecer as ações e objetivos de uma ou mais pessoas a partir de uma série de observações sobre as ações da própria pessoa e as condições ambientais. Essa área é útil para oferecer um suporte personalizado para muitas aplicações diferentes (e.g., comercial, informativa, monitoramento, etc.) e tem conexão com diversos campos de estudo, como medicina, interação humano-computador e sociologia [89].

O HAR é uma tarefa importante para auxiliar a vigilância e a segurança das pessoas em geral. A detecção de atividade humana é desejada, por outro lado, há custos envolvidos para identificá-la automaticamente. Principalmente, os custos relacionados ao transporte, uso e gasto de energia do dispositivo e processamento das informações dos sensores. O uso de sensores acoplados ao corpo ou outros *gadgets* gera custos extras para os usuários [20]. Sensores de ambiente, como câmeras, sensores de vibração e temperatura, já estão disponíveis. No entanto, eles exigem um processamento de informações mais complexo, como o uso de aprendizado de máquina para reconhecimento de face e movimento. Dispositivos móveis, como *smartphones* e *tablets*, geralmente têm um conjunto de sensores embutidos que também estão sendo utilizados para o HAR. Os dois sistemas operacionais móveis mais usados, *Android* [5] e *iOS* [8], oferecem Interfaces de Programação de Aplicativos (API) com detecção de movimento baseada em *Global Positioning System* (GPS) e acelerômetros. Como os *smartphones* já fazem parte de nossos *gadgets* usuais, usar as informações que eles fornecem não impõe nenhum custo adicional aos usuários. O desafio é lidar com o consumo de bateria para coletar e enviar informações dos sensores [16].

Atividades têm um conceito muito amplo que abrange uma variedade de significados e escopo. Caminhar, correr, correr para pegar um ônibus ou almoçar são atividades caracterizadas por um foco diferente. Antes de projetar qualquer modelo de reconhecimento de atividades, deve ser especificado o que queremos dizer com uma atividade, ou seja, quais

informações e dados estão diretamente relacionadas a atividade. Consequentemente, uma ontologia para atividades pode ser necessária pra guiar as coletas de dados e relação entre eles. O reconhecimento de atividades baseado em ontologias tem sido uma abordagem popular para dados relacionados a vídeo e objetos. A primeira diz respeito à inferência de atividades a partir do reconhecimento de gestos [66], útil, por exemplo, para verificar a correção de movimentos relacionados a um tratamento de fisioterapia. O último usa o *affordance* [37] dos objetos na proximidades dos usuários para inferir a atividade que está sendo realizada [75, 76]. No entanto, o foco tem sido principalmente no reconhecimento de atividades em ambientes internos e controlados.

O uso de uma ontologia diminui a dependência de reunir uma grande quantidade de observações rotuladas para permitir que o mecanismos de aprendizagem supervisionada leve a um modelo de reconhecimento de atividades eficaz. A ontologia COSAR [82] combina o conhecimento de uma ontologia como o raciocínio estatístico, enquanto a ontologia Fuzzy-Owl2 [83] inclui representação *fuzzy* na ontologia pra lidar com as possíveis incertezas. As ontologias COSAR e Fuzzy-Owl2 incluem local, tempo e ator (usuário) como conceitos centrais. SOUPA [18] adiciona políticas a este conjunto de conceitos, enquanto CoDAMoS [77] inclui serviços de funções, de *hardware* e de *software*. O uso bem-sucedido de ontologias para reconhecimento em ambientes fechados e ao ar livre inspirou para auxiliar no reconhecimento de atividade ao ar livre a partir de dados de sensores de GPS e perfil do usuário.

Para o HAR, os sensores mais utilizados são acelerômetro, giroscópio e GPS. O acelerômetro e o giroscópio são eficazes quando se trata de atividades físicas, como, mas não limitando a, andar, correr, subir e descer escadas [15, 52, 44, 72]. Infelizmente, esses sensores consomem uma grande quantidade de energia quando usados continuamente, levando os usuários a abandonar aplicativos que dependem desse tipo de recurso. Consequentemente, há uma oportunidade para um protocolo de coleta de dados energeticamente eficiente em dispositivos móveis. O problema é definir a quantidade mínima dos sensores que fornecem informações suficientes para inferir qual atividade o usuário está realizando, identificando atividades de curta (por exemplo, no banco), média (por exemplo, almoçando) e longa (por exemplo, trabalhando) duração.

As propostas atuais têm um custo sensorial bastante elevado, a dependência de vários sensores pode acarretar em um alto consumo de bateria [13, 26, 27, 30, 39, 100]. Diminuindo a quantidade de sensores para o mínimo possível, pode se oferecer resultados semelhantes ou até melhores, dependendo da complementação dos atributos.

No cenário apresentado, a tarefa de HAR pode se beneficiar de fontes adicionais de informações provenientes do ambiente e/ou da *web*. A proximidade de locais previamente classificados em mapas públicos como Pontos de Interesse (Points of Interest - POIs) pode ser utilizada para definir um conjunto de possíveis atividades relacionadas às *affordances* dos lugares. Por exemplo, espera-se que a principal *affordance* de um restaurante seja almoçar/jantar [14, 49]. É claro que existem outras possibilidades, como a atividade "trabalhando", que também é comum para um restaurante. Mas, definitivamente, não se espera que as pessoas rezem ou estudem em um restaurante, embora seja sempre possível, mas não provável. Consequentemente, esse tipo de informação semântica pode ser usada para distinguir entre possíveis atividades estacionárias, isto é, aquelas que um usuário pode executar em um determinado local sem se deslocar. Pensando nessa linha, as informações fornecidas pelo usuário em seu perfil também podem ser usadas para complementar ainda mais os dados sobre os quais é realizada a tarefa de reconhecimento de atividades, oferecendo uma melhora na eficiência dos resultados.

A seleção de atributos também é um assunto recorrente na tarefa de HAR [40, 67, 81, 88, 102]. O foco é selecionar, dentre os atributos coletados, quais atributos são mais eficazes para ajudar a determinar as atividades. Esse ponto é importante, pois a maioria das aplicações derivadas de HAR são feitas para dispositivos móveis onde o custo de processamento e o número de atributos pode ser decisivo para a funcionalidade eficaz das aplicações.

Os primeiros trabalhos sobre HAR são datados do final dos anos 90 [33]. Porém, atualmente ainda existem muitas questões que motivam o desenvolvimento de novas técnicas para melhorar a precisão em experimentos ambientados em cenários reais. Alguns destes desafios que ainda existem são: (1) quais atributos devem ser coletados e quais tem a melhor correlação com as atividades; (2) desenvolvimento de um sistema de aquisição e processamento de dados portátil e barato; (3) desenvolvimento de modelos de extração e inferência de características; (4) aquisição de dados em ambientes reais; (5) flexibilidade do modelo para se adaptar a novos usuários sem a necessidade de refazer o treinamento; e (6) implementação em dispositivos móveis, satisfazendo restrições quanto a processamento e consumo de energia [54].

1.1 Ideia Central

Esta tese apresenta um modelo minimalista de HAR em ambientes fora de casa utilizando dados de GPS e perfil do usuário. A abordagem proposta tem como objetivo englobar o processo completo de HAR, desde a coleta de dados até a concepção de um reconhecedor de atividades. A proposta utiliza o mínimo de sensores possível (apenas um, o GPS) complementando os dados com informações do perfil do usuário para reconhecer um grande conjunto de atividades com eficiência comparável ou melhor que o estado da arte utilizando algoritmos tradicionais da tarefa de classificação.

Os desafios primários desta tese estão listados a seguir:

- Pesquisar quais sensores devem ser utilizados de acordo com estado da arte. Esse levantamento vai permitir que sejam coletados dados que sejam eficientes para ajudar na tarefa de reconhecimento de atividades (detalhado no Capítulo 2).
- Pesquisar trabalhos do estado da arte para comparar diretamente ou indiretamente com a tese apresentada (detalhado no Capítulo 3).
- Gerar um modelo minimalista em termos de sensores e atributos, e eficiente para o reconhecimento de atividades (detalhado no Capítulo 4).
- Realizar o processo de coleta de dados desde a concepção do projeto do aplicativo, baseada na ontologia criada para a coleta, até o pré processamento dos dados para abastecer os *datasets* (detalhado no Capítulo 5).
- Usar algoritmos para seleção de atributos e conseguir grupos de atributos com maior correlação com as classes para testar e verificar a eficiência para o reconhecimento de atividades (detalhado no Capítulo 6).
- Analisar a eficiência do modelo com *Cross-Validation* e avaliar parcialmente com a base de dados *Weeplaces* (detalhado no Capítulo 6).

Os desafios secundários desta tese são listados a seguir:

- Definir uma metodologia para a coleta de dados, podendo ser baseada em uma ontologia.
- Desenvolver um aplicativo para coleta dos dados necessários.

- Definir uma metodologia de pré-processamento de dados.
- Definir as métricas para avaliar a eficiência do modelo.

1.2 Objetivos e Metodologia

O principal objetivo desta tese é propor um novo modelo personalizado de Reconhecimento de Atividades Humana utilizando um conjunto mínimo de atributos do sensor GPS e perfil do usuário. A intenção é alcançar uma combinação mínima de atributos de GPS e perfil do usuário, escolhidos através de técnicas de correlação entre os próprios atributos com as atividades. Com isso, almeja-se alcançar acurácia, precisão, *recall* e *F-Score* semelhantes a dos trabalhos do estado da arte ou melhor. Esta abordagem difere por apresentar uma ontologia para o reconhecimento de atividades em ambientes reais fora de casa, também é demonstrada uma metodologia de seleção de atributos de GPS e a utilização do perfil do usuário aplicados a HAR, e outro diferencial é expor um modelo personalizado através do perfil do usuário.

Outro objetivo deste trabalho é apresentar a metodologia de coleta de dados em ambiente real baseada na ontologia criada, começando pelo aplicativo desenvolvido para o experimento, acompanhamento da coleta e por fim do pré-processamento dos dados para montar o *dataset*. Além de apresentar detalhadamente os atributos que fazem parte do *dataset* e o perfil dos participantes do experimento.

A tese também tem como objetivo fazer um experimento de sensibilidade para testar a correlação entre os atributos coletados com as classes para encontrar uma solução com o melhor compromisso entre menor número de atributos e melhores resultados, solução essa que pode não ser única. Por fim, o último objetivo é testar o modelo gerado e avaliar sua performance através de acurácia, precisão, *recall* e *F-Score* e fazer uma comparação parcial com o *dataset Weeplaces* [11].

1.3 Contribuições

O trabalho relatado nesta tese apresenta as seguintes contribuições relacionadas a tarefa de reconhecimento de atividades humanas:

- Modelo *Minimalist Out-of-home* HAR (MOut-HAR): Um modelo minimalista de HAR em que foram utilizados apenas dados de um único sensor, usando apenas

dados do sensor GPS com uma leitura esparsa de tempo (3 minutos), complementados com dados de POI *online* e dados do perfil do usuário *offline*, com resultados competitivos com o estado da arte.

- Uma ontologia para auxiliar no processo de reconhecimento de atividades com base em dados de GPS e perfil do usuário.
- Uma metodologia de seleção de atributos de dados de GPS e perfil do usuário aplicada a tarefa de HAR.
- *HAR-Brazilian dataset*: Um *dataset* com as atividades rotuladas pelo usuário em ambiente real e aberto com as tarefas diárias.

1.4 Organização

O Capítulo 2 apresenta uma introdução sobre sensores e a tarefa de reconhecimento de atividades, que são conceitos essenciais utilizados no desenvolvimento desta tese. O Capítulo 3 apresenta os trabalhos relacionados sobre assuntos correlatos ao problema apresentado. O Capítulo 4 apresenta detalhadamente o modelo MOut-HAR de reconhecimento de atividades proposto nesta tese. O Capítulo 5 apresenta o processo de coleta de dados, incluindo o aplicativo e a ontologia, e o *dataset* HAR-Brazilian que foi concebido para realizar os experimentos propostos nesta tese. O Capítulo 6 apresenta os experimentos e os resultados finais realizados para validar a proposta. O Capítulo 7 apresenta uma recapitulação desta tese, e por fim, conclui esta tese, discutindo as contribuições alcançadas e questões que permanecem em aberto para trabalhos futuros.

1.5 Artigos Publicados

Com as pesquisas desenvolvidas nesta tese, os seguintes artigos foram publicados (do mais recente até o mais antigo):

- Da Penha Natal, I.; Correia, L.; Garcia, A. C.; & Fernandes, L. "Efficient out-of-home activity recognition by complementing GPS data with semantic information". First Monday, V. 24, N. 11, 2019 [25].
- Da Penha Natal, I.; Cordeiro, R. A. C.; & Garcia, A. C. B. "Activity Recognition Model Based on GPS Data, Points of Interest and User Profile". No International Symposium on Methodologies for Intelligent Systems (ISMIS), Varsóvia, 2017 [24].

- Da Penha Natal, I. "Modelo de Reconhecimento de Atividades Baseado em dados de GPS e contexto de trajetórias". Workshop de Pesquisa e Desenvolvimento em Inteligência Artificial, Inteligência Coletiva e Ciência de Dados (WORKPEDIA), Niterói, 2016 [23].

Capítulo 2

Sensores e Tarefa de Reconhecimento de Atividades

Este Capítulo é dedicado a apresentar uma introdução sobre sensores, atributos e a tarefa de reconhecimento de atividades, sendo esse conceitos fundamentais para o desenvolvimento desta tese. Inicialmente é apresentado o tema sensores com sua relação a tarefa de reconhecimento de atividades, posteriormente são apresentados os principais atributos utilizados nesta tarefa, e por fim, é apresentada a tarefa de reconhecimento de atividades com sua definição e técnicas utilizadas para a sua solução.

2.1 Sensores

Os sensores são elementos fundamentais de todo sistema que necessita coletar dados de uma pessoa, captando atributos em geral com precisão e confiabilidade durante um período de tempo. O rápido desenvolvimento da microeletrônica, micromecânica, óptica integrada e outras tecnologias relacionadas possibilitou o desenvolvimento de vários tipos de sensores inteligentes para detectar e medir dados de forma mais eficiente e rápida, com menor consumo de energia e menos recursos de processamento [69].

Sensores podem estar disponíveis de várias formas para coletar dados de um indivíduo, pode ser um anel, uma camisa, um *smartphone*, um relógio, uma pulseira, um óculos, etc. A maioria dos sensores buscam ser completamente discretos para que o uso deles se torne imperceptível e não invasivo para as pessoas. Dentro desses dispositivos podem haver sensores para medir pressão arterial, acelerômetros, giroscópios, GPS e termômetro, gerando dados para abastecer sistemas que podem proporcionar melhor qualidade de vida para os usuários. Os dados adquiridos a partir destes sensores são processados de acordo

com a exigência, para uma aplicação particular.

No contexto de reconhecimento de atividades, os tipos de dados coletados podem ser divididos em quatro grupos. São eles:

- **Dados Ambientais:** Atributos, como temperatura, umidade, nível de ruído, etc., detinam-se a fornecer informações de contexto, apresentando características do ambiente onde o usuário se encontra. Vários sistemas existentes usam microfones, sensores de luminosidade, termômetros, entre outros [65, 74]. Esses sensores sozinhos, na maioria das vezes, não conseguem fornecer dados suficientes para a tarefa de reconhecimento de atividades. Assim, os dados ambientais devem acompanhar outros tipos de dados para ser efetivo para essa tarefa.
- **Dados de Aceleração:** Acelerômetros triaxiais são um dos sensores mais utilizados no reconhecimento de atividades físicas, ou seja, atividades que sejam determinadas por mudanças de movimento (andando, correndo, lavar louça, etc.) [10, 43, 45, 46]. Acelerômetros são baratos e necessitam de um consumo relativamente baixo de bateria [80], e são embutidos na maioria dos *smartphones* atuais. Um ponto de discussão em relação aos acelerômetros é onde ele deve ficar posicionado: dentro do bolso da calça (*smartphone*) [47], em uma bolsa [65], no cinto [35] ou na mão dominante [91]. A posição ótima para o acelerômetro depende da aplicação e do tipo de atividades a serem reconhecidas. Quando se trata de atividades do cotidiano (trabalhar, estudar, comer, etc.), o acelerômetro não consegue ser efetivo, pois gera muitas similaridades entre as atividades.
- **Dados de Localização:** O GPS permite diversos tipos de serviços baseados em localização. A maioria dos *smartphones* atuais são equipados com esse sensor, fazendo com que ele se torne conveniente para aplicações sensíveis ao contexto. O lugar onde o usuário se encontra pode ser útil para ajudar a inferir as atividades usando raciocínio ontológico [82]. Informações semânticas sobre lugares podem ser obtidas por meio do *Google Places*¹, *Foursquare*² ou *Yelp*³. No entanto, os dispositivos GPS não costumam funcionar bem em ambientes fechados. Geralmente, para auxiliar nas tarefas neste tipo de local, é utilizado o acelerômetro [82]; mas o uso dos dois sensores juntos tornam-se custoso quando se trata de consumo de energia e necessitam de uma carga maior de processamento. Há também o problema referente à

¹<https://developers.google.com/places/>

²<https://developer.foursquare.com/>

³<https://www.yelp.com/developers>

privacidade dos dados pessoais, mas que podem ser resolvidos através de algumas técnicas de criptografia e ofuscação em dados de localização [21, 48, 96].

- **Dados Fisiológicos:** Sinais vitais (batimento cardíaco, frequência respiratória, temperatura corporal, etc.), esse tipo de dados está ligado a saúde dos usuários e os sensores necessitam estar acoplados diretamente na parte do corpo onde são medidos esses sinais. A principal aplicação para o uso desse tipo de dados é para monitoramento de idosos ou de pessoas doentes que necessitam de monitoramento constante desses sinais vitais. Em um trabalho anterior, Tapia *et al.* [91] utilizaram cinco acelerômetros e monitor de batimento cardíaco como fonte de dados, os autores concluíram que o batimento cardíaco não ajudava de forma significativa na melhoria da acurácia no reconhecimento de atividades. Para medir sinais fisiológicos, sensores adicionais seriam necessários, aumentando o custo do sistema e tornando-o obstrutivo [74]. Além disso, esses sensores frequentemente usam comunicação sem fio que implica em um maior consumo de energia.

Os *smartphones* estão cada vez mais eficientes, com os mais variados tipos de sensores embutidos de forma nativa. Com isso, conseguem promover uma experiência mais rica para os seus usuários. Esses sensores ajudam a medir o movimento, posicionamento e algumas condições ambientais, sendo capazes de produzir dados com alta precisão e exatidão. Ainda em termos físicos, são componentes de *hardware* conectados aos dispositivos, de forma a fornecer dados do mundo real para diversas aplicações [6]. Com esses sensores, os *smartphones* se tornaram um dispositivo capaz de ceder dados para que seja possível fazer o reconhecimento de atividades, fortalecendo seu uso em diversos trabalhos [57, 87, 105].

2.2 Tarefa de Reconhecimento de Atividades

Antes de falar da tarefa de reconhecimento de atividades é necessário entender o que são atividades. Atividade é um conceito amplo que abrange uma variedade de significados e escopo. Estudar, fazer compras, almoçar, caminhar, andar de carro ou tomar café são atividades caracterizadas por diferentes níveis de abstração. Conforme definido em Ranasinghe *et al.* [79], as atividades acontecem dentro de um período de tempo. Em alguns casos, as atividades podem ser executadas de modo intercalado ou compostas hierarquicamente. Através do tempo, as atividades seguem um modo sequencial ou simultâneo. Para a descrição temporal das atividades, foi utilizado um modelo baseado nas caracte-

rísticas da álgebra de intervalo de Allen [2, 70]. Essa álgebra permite representar relações entre eventos temporais, como exemplificado na Figura 2.1, onde são mostrados quatro exemplos de divisão de atividades ao longo do tempo.




Figura 2.1: Exemplos de atividades compostas, sequenciais, simultâneas e intercaladas.

Alguns tipos de atividades encontradas na literatura (as mais comumente usadas) são mostradas na Tabela 2.1, e foram divididas em quatro grupos: passeio, transporte, atividades diárias e exercícios.

Tabela 2.1: Tipos de atividades encontrados na literatura.

Grupo	Atividades
Passeio	Andando, correndo, sentado, parado, deitado, subindo escadas e descendo escadas.
Transporte	Andando de ônibus, andando de bicicleta, andando de trem e dirigindo.
Atividades diárias	Comendo, bebendo, trabalhando, assistindo TV e alongamento
Exercícios	Malhando, <i>spinning</i> , caminhada nórdica e fazendo flexões.

Basicamente, a tarefa de reconhecimento de atividades tem três componentes principais:

- Um módulo sensor de baixo nível que reúne continuamente informações relevantes sobre as atividades (acelerômetros, GPS, giroscópio, etc.).

- Um módulo de processamento e seleção de atributos que processa os dados brutos do sensor em recursos para ajudar a determinar as atividades; e
- Um módulo de classificação que usa os recursos para inferir que atividade um indivíduo ou grupo de indivíduos está realizando.

Um atributo pode ser carregado com informações de baixo nível (como conteúdo de frequência e coeficientes de correlação) ou informações de nível mais alto (como o número de pessoas presentes). O *design* de qualquer sistema de Reconhecimento de Atividades depende do tipo de atividades que pretendem ser reconhecidas. De fato, alterando o conjunto de atividades, o problema muda imediatamente, mudando também os sensores e os dados à serem coletados. O Capítulo 5 demonstra cada um desses módulos no modelo proposto.

Algumas técnicas conhecidas da literatura são utilizadas para ajudar a resolver a tarefa de reconhecimento de atividades. Normalmente os dados extraídos são advindos dos mais diversos sensores, e são utilizados como entradas para os algoritmos de classificação. No caso do reconhecimento de atividades humana, os padrões de dados de entrada estão diretamente associados às atividades (classes) consideradas. Em geral, a tarefa de classificação requer a aprendizagem de uma regra de decisão ou de uma função associativa entre os dados de entrada e as classes. Existem duas direções principais nas técnicas de aprendizado de máquina: abordagens supervisionadas e não supervisionadas [29, 98]. As abordagens de aprendizagem supervisionada para classificação como Rede Neural Artificial (RNA) [98] e *Support Vector Machine* (SVM) [95] exigem dados de atividades rotuladas. As abordagens não supervisionadas, como aquelas baseadas em GMM (*Gaussian Mixture Models* - Modelo de Mistura de Gaussiana) e HMM (*Hidden Markov Model* - Modelo Oculto de Markov) [78] (comumente não supervisionada) permitem inferir os rótulos a partir dos dados de entrada.

A tarefa de reconhecimento de atividades é tratada como uma tarefa de classificação supervisionada, pois as atividades geralmente são definidas. Nos próximos parágrafos há uma breve descrição das técnicas mais utilizadas - Árvore de decisão J48, *K-Nearest Neighbors* (KNN), *Multilayer Perceptron* (MLP), *Naive Bayes* (NB), *Random Forest* (RF) e SVM. Para maiores informações sobre as abordagens não supervisionadas, consultar [29, 78, 98].

O algoritmo J48 constrói uma árvore de decisão considerada simples e útil para a tarefa de classificação, ele cria uma árvore binária. Uma árvore de decisão é um modelo

preditivo de aprendizado de máquina que decide a classe de uma nova amostra com base em vários valores de atributos dos dados disponíveis. Os nós internos de uma árvore de decisão denotam os diferentes atributos, os ramos entre os nós nos informam os possíveis valores que esses atributos podem ter nas amostras observadas, enquanto os nós terminais nos informam a classe das amostras. A nova amostra a ser classificada é conhecida como variável dependente, pois seu valor depende ou é decidido pelos valores de todos os outros atributos. Os outros atributos, que ajudam a prever o valor da variável dependente, são conhecidos como variáveis independentes no conjunto de dados [1].

O KNN [29, 92] é uma técnica de classificação supervisionada que pode ser vista como um método de classificação direta, porque não requer um processo de aprendizagem. O único requisito é o armazenamento de todos os dados. Para classificar uma nova instância, o algoritmo KNN utiliza o princípio de similaridade (distância) entre o conjunto de treinamento e a nova observação para classificar. A nova instância é atribuída à classe mais comum através de um voto majoritário de seus k vizinhos mais próximos. A distância dos vizinhos de uma instância é calculada usando uma medida de distância chamada função de similaridade, como distância euclidiana. Além disso, deve-se notar que, ao usar a abordagem KNN, uma nova amostra é atribuída a uma classe [93].

O MLP [84], é uma RNA com arquitetura multicamadas *feed-forward* e é, em geral, baseada em ativações não lineares para as unidades ocultas. O MLP busca minimizar a função de erro entre as saídas da rede, estimadas e desejadas, que representam os rótulos das classes no contexto de classificação. Vários estudos [3, 17, 93] mostram que o MLP é eficiente em problemas de classificação não linear, incluindo o reconhecimento de atividades.

O algoritmo NB faz parte da abordagem de aprendizado da estatística Bayesiana que lida com um classificador probabilístico simples, baseado na aplicação do teorema de Bayes. Em termos simples, um classificador NB assume que a presença (ou ausência) de uma característica em uma classe não está relacionada à presença (ou ausência) de qualquer outra característica. Embora os atributos sejam dependentes entre si, um classificador NB considera todas as propriedades de forma independente. Apesar de seu design ingênuo e suposições aparentemente simplistas, o algoritmo é rápido e incremental, além de poder lidar com atributos discretos e contínuos, possui excelentes resultados em problemas da vida real [99].

As RFs [62] consistem em uma floresta de árvores de decisão, melhorando o desempenho de classificação de uma árvore única, combinada ao método de agregação *bootstrap* e

a randomização na seleção de nós de dados de particionamento na construção da árvore de decisão. A atribuição de um novo vetor de observação a uma classe é baseada em um voto majoritário das diferentes decisões fornecidas por cada árvore que constitui a floresta. No entanto, RF precisa de uma quantidade alta de dados rotulados para conseguir bons desempenhos de classificação.

SVM é uma técnica de aprendizado de máquina introduzida por Vapnik [95]. É um classificador derivado da teoria de aprendizagem estatística. Esta técnica minimiza um risco empírico (como uma função de custo) e, ao mesmo tempo, maximiza a margem entre o chamado hiperplano de separação e os dados. Por padrão, SVMs são classificadores lineares. No entanto, a classificação não linear torna-se possível através da extensão de SVM usando métodos *kernel* [85]. A ideia central dos métodos de *kernel* é projetar os dados do espaço original para um espaço de alta dimensão, chamado espaço de atributo, usando uma função não linear determinada do *kernel*. Uma separação linear no espaço de atributo resultante pode ser obtida usando o *Cover's theorem* [22]. Além disso, SVM é um classificador binário; portanto, para garantir uma classificação multi-classe, podem ser utilizadas classificações pareada (um SVM é definido por uma classe contra todos os outros convexos, para todas as classes de otimização), o que torna demorado, especialmente no caso de uma grande quantidade de dados.

Para uma discussão mais aprofundada sobre os algoritmos, suas configurações e/ou variações, usados para reconhecimento de atividades, consulte os trabalhos [22, 84, 99].

2.3 Discussão

Esse Capítulo apresentou uma sumarização dos componentes utilizados nesta tese. As definições apresentadas auxiliam na continuação do trabalho para facilitar o entendimento posterior dos termos expostos.

Para esta tese foi escolhido o uso de sensores dos *smartphones* para coletar dados, a escolha foi feita devido a grande maioria das pessoas terem o dispositivo, não tendo custos adicionais (além do custo do aparelho). Dentre os sensores possíveis foi escolhido somente o GPS, pois a proposta apresentada visa a eficiência energética usando o mínimo de sensores possível, neste caso, apenas um. A escolha é fundamentada pelas atividades que serão reconhecidas no modelo proposto, a maioria delas são atividades fortemente acopladas à localização. Para este trabalho foram escolhidas apenas as atividades sequenciais, pois são uma abstração da rotina da maioria das pessoas e são mais práticas para

serem identificadas. Dentre as atividades utilizadas para o experimento desta tese estão as de passeio, transporte e atividades diárias. Para os experimentos feitos nesta tese, foram utilizadas as seis técnicas supervisionadas de reconhecimento de atividades apresentadas: J48, KNN, MLP, NB, RF e SVM. Seguindo os conceitos apresentados e as escolhas feitas, o Capítulo a seguir apresenta trabalhos do estado da arte com essas características.

Capítulo 3

Trabalhos Relacionados

Este Capítulo é dedicado a apresentar trabalhos relacionados ao tema de reconhecimento de atividades humanas usando o GPS que é abordado nesta tese de doutorado. Assim, trabalhos relacionados ao uso de GPS para reconhecer atividades, ontologias para HAR e seleção de atributos em HAR, entre outros, são apresentados e discutidos.

Para esta tese, existem dois grupos separados de atividades: estacionárias (almoçar, trabalhar, fazer compras, etc.) e de movimento (andando, andando de carro e andando de ônibus), em alguns trabalhos da literatura as atividades de movimento são chamadas de modos de viagem [87, 105, 103].

3.1 GPS em HAR

Zheng *et al.* [103] apresentam como objetivo entender o comportamento de mobilidade das pessoas através do modo de transporte detectado pelo GPS. Os modos de transporte utilizados para o trabalho foram: dirigindo, andando, andando de ônibus e andando de bicicleta. Eles identificaram um conjunto de atributos (*heading change rate*, *stop rate* e *velocity change rate*) mais robustos, em relação ao estado da arte, para entender a condição de tráfego e ajudam a melhorar a acurácia da inferência. Eles coletaram dados de 65 usuários em um período de 10 meses. Foram utilizados 9 atributos semânticos. Os resultados foram de 76% em termos de *recall* e precisão. As principais limitações do trabalho são os resultados abaixo de 90% e o uso de um número elevado de atributos semânticos.

No trabalho de Shin *et al.* [87] são usados acelerômetro e GPS de *smartphones* para reconhecer modos de viagem. Eles trabalharam com o reconhecimento dos seguintes

modos de viagem: andar, no carro, no trem e no ônibus. Os dados utilizados foram compostos por 495 amostras de 30 usuários na cidade de Zurique. O modelo apresentado teve resultados de acurácia de 82%. As principais limitações deste trabalho são o número restrito de instâncias utilizadas e os resultados de acurácia abaixo de 90%.

No trabalho de Zhou *et al.* [105], os autores usam o acelerômetro e o GPS de *smartphones* para detectar os modos de viagem dos usuários. Os modos de viagem reconhecidos são: andando, correndo, de bicicleta, dirigindo e parado. A coleta de dados foi feita com 12 voluntários durante 6 dias coletando de 20 em 20 segundos, totalizando 9.981 instâncias. Os resultados de acurácia foram de 93,8%. As principais limitações deste trabalho são a utilização de um pequeno conjunto de dados e também não foi feita nenhuma análise de consumo energético, visto que foram utilizados dois sensores com intervalos de coleta pequeno.

O trabalho de Van Dijk [94] tem como objetivo classificar um ponto de GPS como pontos de atividade ou pontos de movimento. Os pontos de GPS foram criados artificialmente contendo vários níveis de ruído. A informação dos atributos é complementada com informações derivadas das múltiplas janelas espaciais sobre pontos anteriores e posteriores. Foram utilizados 16 atributos semânticos. O algoritmo *Random Forest* apresentou os melhores resultados de acurácia de 99,4% com a janela de tempo de 30 segundos e de 99% com a janela de tempo de 60 segundos. As limitações do trabalho são o uso de pontos de GPS artificiais e somente distinguem entre uma atividade estática ou um ponto de movimento.

No trabalho de Lee & Kwan [57] são utilizados o acelerômetro e o GPS de *smartphones* para classificar atividades físicas. As trajetórias do GPS ajudaram a visualizar os erros e melhoraram a precisão das atividades. Os autores consideraram apenas as atividades: correndo, andando, sentando e parado em pé. A coleta de dados do GPS foi com intervalo de 1 segundo e do acelerômetro de 20 amostras por segundo de 36 pessoas, totalizando 1.098.207 instâncias. Foram utilizados 59 atributos. Os algoritmos *Random Forest* e *Gradient Boosting* apresentaram acurácia de 99,03% e 99,22%, respectivamente. Nenhuma análise de eficiência energética foi realizada, foram utilizados apenas atributos semânticos do acelerômetro e o número de atributos de entrada utilizados para os algoritmos foi grande.

Difrancesco *et al.* [28] utiliza informações de GPS e POI para identificar atividades fora de casa de pacientes com esquizofrenia. Seis áreas de atividades foram definidas, associadas a diferentes POIS: trabalho, compras, esportes, social, recreação e outras.

Foram coletados dados de 5 pacientes durante 5 dias toda vez que a mudança de posição era de 10 metros em relação a anterior. Foram feitos testes com intervalos de 5, 6, 8 e 10 minutos. Os resultados de *recall* foram entre 65 a 71% e precisão foram entre 66 a 95%. As limitações do trabalho são a dependência do usuário anotar todas as atividades em um diário, os resultados de *recall* abaixo de 80% e o uso de um grupo específico (pacientes esquizofrênicos) limitando o número de voluntários.

No trabalho de Boukhechba *et al.* [14] foram usados dados de GPS de dispositivos móveis junto com informações de POI para identificar atividades em movimento e parada. As categorias de atividades consideradas no trabalho foram: alimentação, educação, entretenimento, transporte, financeiro e saúde. Apenas dados de um usuário foram utilizados para avaliação da acurácia com intervalo de tempo de coleta de 10 segundos com velocidades maiores que 10 km/h e 5 segundos para velocidades menores. Os resultados foram considerados pelos autores como sendo bem sucedidos na inferência de atividades de longa duração, mas com limitações em algumas atividades de curta duração. A atividade em casa não foi definida no modelo ficando como parado em um endereço, o que levou os autores a sugerirem o registro do endereço residencial como opção para melhorar o modelo. Eles sugerem incluir o perfil do usuário para melhorar os resultados. O trabalho coloca a acurácia como métrica de avaliação, porém não apresenta os resultados estatísticos. O uso de apenas um usuário pode fazer com que o modelo sofra *overfitting*.

No trabalho de Huang *et al.* [49] foi definida a atratividade do POI (dependendo do tamanho e da popularidade), juntamente com sua categoria para prever as atividades do usuário a partir de sua trajetórias obtidas pelo GPS, são identificadas seis atividades diferentes: alimentação, compras 1, compras 2, entretenimento, órgãos públicos e outras. Foram coletados dados de 10 voluntários, totalizando 8.089 amostras. A acurácia variou de 70% até 100%, de várias atividades em grupos de POIs a atividades únicas em um POI isolado. O número de amostras e a precisão das atividades múltiplas são as limitações do trabalho.

O trabalho de Liao *et al.* [59] obteve informações sobre POIs de banco de dados geográficos e usaram uma rede de Markov relacional para identificar locais significativos para um indivíduo com base em seu padrão de movimento. Eles consideram que as atividades são fortemente associadas aos locais. Foi utilizado um conjunto de sete atividades: trabalhar, dormir, lazer, visitar, pegar, ligar/desligar carro e outras. Os resultados da identificação do local atingiram mais de 90% de acurácia. O trabalho não busca reconhecer a atividade que está sendo executada, ele procura saber qual local está sendo feita

determinada atividade.

3.2 Seleção de atributos e ontologias para HAR

A seleção de atributos e ontologias para HAR não tem nenhuma relação direta, a junção dos dois assuntos em uma única seção foi feita pela pequena quantidade de trabalhos encontrados sobre os dois conteúdos.

O trabalho de Ribeiro *et al.* [81] apresenta uma metodologia para seleção de atributos de vídeos para HAR. Os autores utilizaram um conjunto inicial de 29 atributos, que descrevem o movimento global dos usuários, bem como o movimento local dentro da região de interesse. Foram propostos alguns métodos de seleção de atributos (*brute search*, *lite search* e *Lite-lite search*) para avaliar a taxa de reconhecimento com o classificador *Bayesiano*. Os testes foram feitos para reconhecer 5 atividade: ativo, inativo, andando, correndo e lutando. As imagens utilizadas foram imagens reais, com diferentes sequências de imagens de treino e teste. Os resultados com o uso de 12 atributos diferentes foram de 94,4%.

Zhang & Sawchuk [102] apresentam uma metodologia de seleção de atributos de acelerômetro, giroscópio e magnetômetro (*physical features*). Um total de 110 atributos, incluindo 87 estatísticos e 23 físicos, foram coletados. Foram usadas as técnicas *Relief-F*, *SFC* e *SFS*. Foi verificado que a partir de 50 atributos os resultados não foram efetivamente melhorados. Então foram feitos testes com os top 50 atributos de cada uma das técnicas.

O uso de ontologia na tarefa de reconhecimento de atividades tem sido usado principalmente como uma forma de apoiar o raciocínio, o objetivo é facilitar o entendimento de relação entre os atributos, e com isso, melhorar os resultados. Riboni & Bettini [82] definiram uma ontologia de atividades com essa intenção como parte de uma ontologia mais geral, O ActivO, para o domínio de reconhecimento de atividades em ambientes internos e externos. As propriedades diretamente associadas à atividade são a extensão de tempo, localização simbólica e a pessoa que a executa. Quatro voluntários diferentes, de um grupo de seis, realizaram cada atividade por 450 segundos, usando acelerômetro e GPS de um *smartphone*, além de um dispositivo de pulso com acelerômetro e sensores de intensidade de luz e temperatura. As instâncias de atividades foram consideradas em segmentos de 1 segundo de duração. Os resultados do classificador projetado por pessoas que combina reconhecimento de atividades estatística e ontológica é capa de atingir uma

acurácia de 93,44%.

Chen & Nugent [19] definem uma ontologia de camada única em que a atividade é associada a: super atividade, sub atividade, tipo de atividade, ator, localização, recursos, entidades do ambiente, duração, objetivo, efeitos, condições e tempo. A ontologia foi projetada para um ambiente de *smart home*. O raciocínio é baseado na lógica de descrição para inferir atividades das relações ontológicas. Um exemplo de cenário único é apresentado passo a passo para ilustrar o processo.

Um ambiente de *smart home* também é o contexto da ontologia desenvolvida por Noor *et al.* [71]. A ontologia é composta por cinco conceitos principais: sensor, localização, objeto, ação e atividade. O raciocínio combina as informações da ontologia com a incerteza, o que pode explicar dados desconhecidos. O processamento da incerteza é suportado pela teoria da evidência Dempster-Shafer, estendendo o simples raciocínio ontológico para reconhecer atividades. São relatados dois experimentos, um realizado com 20 voluntários e o outro por 10 voluntários, em ambos os casos foram realizadas uma sequência predefinida de ações de duração também predefinida. A acurácia relatada é, em ambos os experimentos, de 93%.

O trabalho de Mousavi *et al.* [68] propõe uma ontologia de trajetória semântica para apoiar o reconhecimento de atividades ao ar livre. É o único que combina ontologia com informações de POI. No entanto, ele não apresenta uma ontologia de atividade. As atividades são realizadas apenas quando o usuário para em algum POI, e são classificadas em 10 tipos: alimentação, recreação, educação, volta para casa, socialização, compras, compras diárias, serviços, ir para o trabalho e viagem. Axiomas escrito pelos pesquisadores são usados para reconhecer essas atividades. Os dados experimentais de um único usuário durante um ano. A acurácia foi superior a 86%, exceto para o reconhecimento das atividades educação (69,5%) e compras diárias (35,9%).

A integração das informações do perfil do usuário para melhorar o refinamento de reconhecimento de atividades é escassa na literatura. Durante esta pesquisa foram encontrados apenas dois trabalhos onde há a relação de perfil do usuário com reconhecimento de atividades [19, 38]. Nos dois casos, a abordagem é associar perfis de atividades específicos a cada usuário. Em Chen & Nugent [19], o perfil é uma instância da ontologia que descreve a atividade obtida das preferências do usuário. Por outro lado, em Gomes *et al.* [38], o perfil é uma probabilidade específica de distribuição conjunta associando dados do sensor à atividade. Não foram encontrados trabalhos que integrem atributos do perfil do usuário (sexo, profissão, idade, etc.) juntamente aos atributos dos sensores para

melhorar os resultados de reconhecimento de atividades.

3.3 Discussão

Os trabalhos correlatos apresentados neste Capítulo foram discutidos e apresentaram várias limitações que auxiliaram para o desenvolvimento do modelo proposto nesta tese. Os trabalhos tem limitações em termos do número e do tipo de atividade reconhecida, apresentando atividades de movimento [57, 86, 87, 105] ou atividades estacionárias [49, 14, 28], em um total de quatro a seis atividades. Os trabalhos de Boukhechba *et al.* [14], Chen & Nugent [19] e Gomes *et al.* [38] sugerem que o uso dos dados do perfil do usuário podem ser atributos para melhorar o refinamento de reconhecimento de atividades. No entanto, nenhum deles realmente usa essa informação. Os trabalhos baseados apenas no sensor GPS [14, 28, 49, 59, 97] usaram de um a dez voluntários para obter os resultados. Os trabalho de Difrancesco *et al.* [28], Huang *et al.* [49], Shin *et al.* [87] e Zheng *et al.* [103] apresentaram resultados limitados, entre 70% e 82 % (valores de acurácia, *recall* ou precisão, dependendo do trabalho). Os trabalho de Boukhechba *et al.* [14], Shin *et al.* [87], Van Dijk [94], Wan & Lin [97] e Zhou *et al.* [105] apresentaram um intervalo de tempo de coleta de dados dos sensores abaixo de 60 segundos, podendo implicar em um alto consumo energético. Os trabalhos de Boukhechba *et al.* [14], Huang *et al.* [49], Liao *et al.* [59] e Shin *et al.* [87] utilizaram *datasets* pequenos, contendo menos de 10.000 instâncias. Os trabalho de Lee & Kwan [57], Liao *et al.* [59], Van Dijk [94] e Zheng *et al.* [103] usaram mais de três atributos semânticos.

Capítulo 4

Modelo MOut-HAR

O modelo minimalista de reconhecimento de atividades humana fora de casa (*Minimalist Out-of-home Human Activity Recognition* - MOut-HAR) é apresentado na Figura 4.1, onde as caixas azuis e amarelas representam processos da tarefa de reconhecimento de atividades. No nosso modelo duas fases são representadas, na parte de cima da Figura 4.1 é a fase de geração e na parte de baixo é a fase de execução. Processos com o mesmo nome são idênticos nas duas fases. Os processos funcionam como descrito a seguir:

- Sensoriamento: Os dados brutos são coletados do GPS e do relógio do *Smartphone* fornecendo as informações necessárias sobre o ambiente e o tempo.
- Processamento de Sinal: Os dados recebidos no sensoriamento são pré-processados, gerando os atributos básicos para o *dataset* e a para o processo de extração de *features*.
- Perfil do Usuário: O dados do perfil do usuário são solicitados de forma *offline*.
- Extração de *Features*: Esse processo é executado para obter informações simbólicas dos atributos básicos, adicionando atributos enriquecidos ao *dataset*. Seu objetivo é minimizar o conteúdo de dos dados, maximizando as informações fornecidas por eles.
- Geração de modelos para HAR: Esse processo recebe os atributos do *dataset* e aplica técnicas de aprendizado de máquina para gerar um modelo treinado.
- Reconhecedor de HAR: Esse processo recebe novos dados de sensoriamento e de perfil do usuário e realiza uma classificação usando o modelo treinado para reconhecer uma atividade.

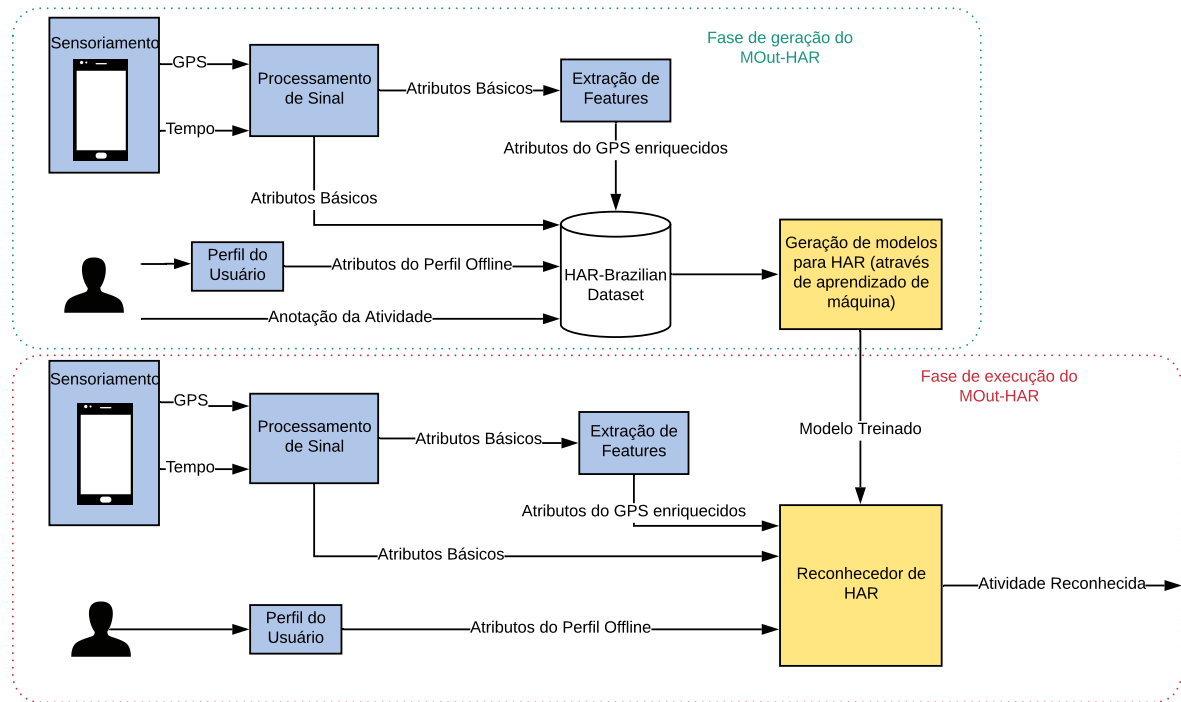


Figura 4.1: Fluxograma do Modelo MOut-HAR. A fase de geração do modelo está acima da fase de execução.

No modelo MOut-HAR são utilizados dados de diferentes fontes de informação, por isso é importante o uso de um modelo de fusão de dados. Entre os modelos mais utilizados para fusão de dados estão o *Joint Directors of Laboratories - JDL* [61] e o *Waterfall* [64]. Os modelos visam padronizar o processamento de dados brutos em uma aplicação que precisa usar as informações adquiridas com certo nível de similaridade. O *Waterfall* é apresentado como um modelo mais simples em comparação ao JDL, embora com capacidade semelhante na tarefa de fusão de dados. O modelo de fusão de dados *Waterfall* foi proposto por Markin *et al.* [64], essa arquitetura enfatiza as funções de processamento nos níveis mais baixos, levando o fluxo de dados do nível de dados para o nível de tomada de decisão. Para este trabalho, uma abstração do modelo *Waterfall* foi utilizada para integrar diferentes fontes de informação apresentada na Figura 4.2, onde as caixas azuis são processos que usam sempre a mesma abordagem e as caixas amarelas são processos que foram testados com a implementação de diferentes abordagens. Para informações mais aprofundadas dos modelos de fusão de dados, consulte os trabalhos [31, 41, 63].




Figura 4.2: Fluxograma do Modelo *Waterfall*. As caixas coloridas em azul e amarelo representam os processos utilizados pelo nosso modelo. As caixas azuis representam os processos que usam a mesma abordagem e as caixas amarelas representam os processos com diferentes abordagens.

4.1 Sensoriamento

O processo de sensoriamento apresentado na Figura 4.1 é idêntico nas fases de geração e execução. O processo visa coletar dados de acordo com os requisitos do MOut-HAR e é detalhado nesta seção.

O uso massivo de vários sensores diminui a vida útil da bateria dos *smartphones*, fazendo com que o consumo de energia se torne um problema para os usuários. No trabalho de Wan & Lin [97], vários intervalos de tempo de para coleta de dados do GPS foram testados: 5, 15, 30, 45, 60, 75, 90, 105, 120, 135, 150, 165 e 180 segundos. O melhor compromisso entre o intervalo de coleta de dados e o número de atividades reconhecidas foi de 75 segundos para 167 atividades reconhecidas. No entanto, as atividades identificadas possuem um alto grau de detalhamento. Por exemplo, Wan & Lin assumem que *Esperando transporte*, *Subindo no ônibus* e *Descendo do ônibus* são atividades diferentes. Para esse trabalho, foram utilizadas as atividades *Esperando transporte* e *Deslocamento de ônibus*. Portanto, nesse trabalho o número de atividades reconhecidas e o detalhamento é menor do que o apresentado por Wan & Lin [97]. Considerando essa diferença no nível de detalhamento, novos testes foram realizados para definir o intervalo de tempo apropriado para o cenário desse trabalho. Para obter um consumo de energia adequado

no módulo de sensoriamento do modelo desse trabalho, foi feita uma análise experimental para identificar o maior tempo entre leituras consecutivas de dados de GPS com uma acuidade de dados aceitável, pois a acurácia da localização depende disso. O experimento foi dedicado a verificar o consumo de energia utilizando o aplicativo para coleta de dados. Nenhuma ferramenta foi considerada pra reduzir o consumo energético, apenas aqueles que o próprio sistema disponibiliza por padrão.

Os dados experimentais foram coletados durante 10 horas consecutivas em um telefone modelo *Samsung S5 New Edition* com processador *octa-core* de 1.6 GHz de 64 bits, 2 GB de memória RAM e sistema operacional Android 5.1 no modo padrão de consumo de energia. Foram feitas medições em intervalos 1, 3, 5 e 10 minutos, conforme mostrado na Tabela 4.1. Intervalos de amostragem mais curtos revelaram uma perda significativa de pontos de dados possivelmente devido a falhas do aplicativo ao acessar o GPS nos instantes programados. No sistema operacional Android, a perda de dados ocorre quando o usuário está usando mais de um aplicativo tentando acessar o GPS simultaneamente, isso ocorre porque quando um aplicativo acessa o sensor de GPS, as leituras de outros aplicativos são bloqueadas, o que leva a descartar leituras de dados na fila. De acordo com a análise feita, o intervalo de tempo mais curto (1 minuto) produz a maior quantidade de dados, por outro lado, é o que mais consome bateria e tem a maior taxa de perda de dados. O intervalo de tempo mais longo (10 minutos) não tem perda de dados, mas, com esse intervalo, a detecção adequada da transição de atividades se torna uma questão crítica. Os intervalos de 3 e 5 minutos resultam em consumo de bateria e perda de dados semelhante, mas uma falha na leitura de 5 minutos causaria um intervalo de 10 minutos sem informação. No caso de 3 minutos, uma ou até duas falhas consecutivas causariam um máximo de 9 minutos sem informação. Para os usuários, o importante é manter o consumo de bateria baixo. Como a diferença entre os dois cenários (3 e 5 minutos) é praticamente imperceptível para o usuário (de acordo com a Tabela 4.1, menos de 2% entre 5,57% e 7,19%), por isso o intervalo de 3 minutos foi escolhido para a coleta de dados. Essa escolha acarretou em um benefício extra de filtrar leituras com pouca informação de pontos que ocorrem durante um deslocamento ou em outras situações. Além disso, a filtragem em leituras de movimento é realizada utilizando o atributo *Distância do ponto anterior* (representado como d na Tabela 4.2). A filtragem e a discretização dos dados correspondem ao processo *processamento de sinais* do modelo apresentado.

Tabela 4.1: Consumo energético sensorial e perda de informação em intervalos de tempo diferentes.

Intervalo de tempo	Consumo Energético	Leituras perdidas
A cada 10 minutos	4,04%	0,0%
A cada 5 minutos	5,57%	8,3%
A cada 3 minutos	7,19%	15,0%
A cada 1 minuto	12,32%	30%

Tabela 4.2: Discretização dos atributos de GPS e do relógio

Atributo	Faixa	Discretização
Dia	Segunda-Sexta Fim de semana & Feriado	Útil Não Útil
Tempo inicial/final (hh:mm)	05:30-12:14 12:15-18:17 18:18-22:32	Manhã Tarde Noite
Duração (t em mm:ss)	$t \leq 18:49$ $18:49 < t \leq 39:53$ $t > 39:53$	Baixa Média Longa
Distância do ponto anterior (d em metros)	$d = 0$ $0 < d \leq 234$ $234 < d \leq 453$ $d > 453$	Nula Pequena Média Longa
Velocidade (p em km/h)	$p = 0$ $0 < p \leq 5,45$ $5,45 < p \leq 33,22$ $p > 33,22$	Nula Pequena Média Alta

4.2 Processamento de Sinais

O processamento de sinais da Figura 4.1 é idêntico nas fases de geração e de execução. A função desse processo é reunir as operações para pré-processamento dos dados, que são detalhadas a seguir.

Os dados de GPS brutos e os atributos relacionados ao relógio foram tratados e discretizados em algumas categorias cada um. Isso permitiu o uso de técnicas de aprendizado supervisionadas bem estabelecidas para executar a tarefa de reconhecimento de atividades. Para orientar a discretização, os valores dos atributos tempo inicial/final, duração, distância do ponto anterior e velocidade foram pré-processados usando o algoritmo *K-means* com três configurações diferentes para clusterização: $k = 3, 6$ e 9 (separando os valores igual a 0, quando aplicável, como nulo) e o atributo dia foi discretizado como útil e não útil. Os resultados do uso do *K-means* foram semelhantes. Por uma questão de

simplicidade e diminuição na carga de processamento, foi utilizado o $k = 3$. Os atributos obtidos do GPS e do relógio são apresentados na Tabela 4.2. Nesta Tabela, os atributos coletados são apresentados na primeira coluna. A segunda coluna mostra a faixa de discretização, enquanto a terceira coluna mostra o valor assumido pela discretização.

Dos pontos coletados sucessivamente pelos sensores, a distância percorrida pelo usuário é calculada continuamente, assim como a *velocidade* resultante, que é definida por *distância / duração*. Enquanto a *velocidade* não varia, a distância é acumulada na atividade atual. Uma vez que uma mudança na *velocidade* é detectada, a atividade atual termina e uma nova atividade começa. Consequentemente, uma atividade é imediatamente sucedida por outra sem nenhuma interferência entre elas (similar ao trabalho de Fox *et al.* [34]). Portanto, o *tempo final* da atividade $A^{(t)}$ coincide com o *tempo inicial* da atividade $A^{(t+1)}$.

4.3 Extração de *Features* e Perfil do Usuário

Os processos de extração de *features* e perfil do usuário apresentados na Figura 4.1 são idênticos nas fases de geração e de execução. Seus papéis dentro do modelo são detalhados nesta seção.

Os dados do sensor GPS fornecem uma sequência de pontos de localização. O atributo *velocidade* foi derivado da distância entre os pontos do GPS e as informações de tempo, fornecendo informações para segmentar o fluxo e determinar a janela da atividade realizada. A partir dos pontos adquiridos pelo GPS, é recuperado o POI, que por sua vez foi associado a locais visitados por um lapso de tempo significativo, isto é, no mínimo 2 pontos de GPS sucessivos coletados no mesmo lugar.

Cada POI é de um tipo e oferece intrinsecamente um conjunto de *affordances* de atividades que podem ser realizadas no local. O tipo de POI é recuperado diretamente do *Google Places*¹. A Figura 4.3 ilustra informações mapeadas de POI obtidas através do *Google Places POI Auto Map* que servem para exemplificar como são vistos os POIs dentro de um mapa. Os *affordances* de um POI consideram as possibilidades de atividades que podem ser realizadas no POI [53]. Ele representa a informação semântica sobre o local, que é um atributo importante para determinar a atividade realizada [28, 59]. Nesse trabalho, cada local é identificado por um nome, latitude, longitude e categoria ao qual ele pertence. Para cada categoria de lugares, foram observadas características para

¹<https://developers.google.com/places/?hl=pt-br>

estabelecer as *affordances* locais associadas. Essas relações foram definidas de acordo com o trabalho de Furletti *et al.* [36] e considerando a experiência do autor e voluntários. A Tabela 4.3 demonstra a relação dos POIs adquiridos pelo *Google Places* transformados em categorias de POIs, os POIs foram juntados em conjuntos que representam de forma mais geral a categoria a qual pertencem. No entanto, essas categorias nem sempre tem uma relação direta com a atividade do usuário. Para ilustrar essa falta de relação, analisando as atividades registradas em cada POI nos dados experimentais coletados, apresentados na Tabela 4.4. Por exemplo, a atividade *comprando* foi registrado com as seguintes categorias de POI: *financeiro*, *comida* e *compras*. Todos os relacionamentos são apresentados na Tabela 4.4. Em resumo, *affordances* reduzem o conjunto de atividades prováveis que podem ser executadas em um determinado local. Em vez de recuperar as *affordances* de uma lista pré-definida, foi preterido que ela deve ser aprendida com a observação real, como foi feito com a base de dados desse trabalho.



Figura 4.3: Exemplo de POIs localizados em um mapa. Essa imagem foi obtida do *Google Places* usando o *Point of Interest Auto Map*³.

A extração de *features* do GPS (Extração de *features* da Figura 4.1) recupera valores para o atributo semântico *on-line* categoria do POI. A seleção dos POIs foi baseada nos algoritmos apresentados por Fulletti *et al.* [36], primeiro é feito o enriquecimento semântico das trajetórias, verificando se há POIs vinculados as coordenadas do GPS. O tipo de POI

³Fonte da imagem: <http://www.webdesignndev.com/wp-content/uploads/2013/02/7-The-Wall11.jpg>

Tabela 4.3: Relação entre o tipo de POI de acordo com o *Google Places* e as categorias de POI.

POI (informação retirada do <i>Google Places</i> em inglês)	Categoria do POI
Library, School, University	Educação
Aquarium, Movie_theater, Museum, Night_club, Park, Stadium	Entretenimento
ATM, Bank, Finance	Financeiro
Bakery, Bar, Cafe, Food, Restaurant	Comida
Lawyer_office	Lei
Church, Place_of_worship	Religião
Establishment	Services
Book_store, Clothing_store, Convenience_store, Department_store, Electronics_store, Furniture_store, Grocery_or_supermarket, Hardware_store, Home_goods_store, Jewelry_store, Pet_store, Pharmacy, Shoe_store, Shopping_mall	Compras
Airport, Bus_station, Parking, Taxi_stand	Transporte
Beauty_salon, Car_dealer, Car_rental, Car_repair, Car_wash, Courthouse, Dentist, Doctor, Fire_station, Gas_station, General_contractor, Gym, Hair_care, Health, Hospital, Laundry, Local_government_office, Lodging, Null, Pharmacy, Police, Post_office, Veterinary_care	Outros

Tabela 4.4: Relação entre a categoria do POI e as atividades observadas no HAR-BRAZILIAN-MG Dataset

	Jantando	Deslocamento de ônibus	Deslocamento de carro	No banco	Almoçando	Rezando	Divertindo	Comprando	Estudando	Tomando café	Esperando transporte	Andando	Trabalhando
Educação)	–	–	–	–	33	–	–	–	943	–	12	–	5.428
Entretenimento	–	–	–	–	–	–	954	–	–	–	–	–	–
Financeiro	2	–	–	835	51	–	–	19	–	–	47	12	343
Comida	1.002	–	–	68	1.692	59	–	25	–	800	28	–	171
Lei	–	–	–	–	–	–	–	–	–	–	–	–	629
Religião	360	–	–	–	–	901	–	–	–	–	–	–	–
Serviços	–	–	–	–	–	–	–	–	–	–	–	–	324
Compras	–	–	–	–	–	–	–	1.585	–	–	–	–	–
Transporte	–	–	124	–	–	–	–	–	–	–	717	–	–
Outros	575	6.774	13.986	–	3.343	26	–	–	2.161	352	–	1.366	1.561

recuperado é o que tem maior classificação entre o conjunto de tipos atribuídos pelo *Google Places* entre os POIs abertos mais próximo em um raio de 200 metros.

Em Amato & Straccia [4], os atributos do perfil do usuário são coletados para enriquecer o conjunto de dados e refinar os resultados de livros sugeridos em uma biblioteca

digital. No trabalho de Yu *et al.* [101], os dados coletados de sensores de *smartphones* são utilizados para inferir o perfil do usuário, ou seja, traços de idade, sexo e personalidade. Ambos os trabalhos utilizam apenas os atributos que têm efeito significativo na melhoria dos resultados. Levando isso em consideração, para esta tese, foi realizado um estudo preliminar com os atributos do GPS e os respectivos registros de data e hora. A partir deste estudo, foi possível observar que a maioria das classificações erradas estavam entre dois pares de atividades: andando de carro *versus* andando de ônibus e trabalhando *versus* estudando. Os dados do perfil do usuário coletados para o estudo piloto consistiram em: idade, sexo, profissão, endereço e se o voluntário possui carro. No entanto, idade, sexo e endereço são informações que não fizeram uma diferença significativa em termos de acurácia no estudo piloto, além disso, essas informações combinadas possibilitam a identificação direta dos voluntários, devido a isso, essas informações foram descartadas. A utilização da informação de profissão ajudou a melhorar o refinamento entre a atividade trabalhando e outras (por exemplo, no banco e estudando). O uso da informação sobre o voluntário ter carro foi importante para melhorar a precisão de distinção entre andando de carro e andando de ônibus. Portanto, para o modelo proposto nesta tese, o perfil do usuário é coletado através de um processo manual *off-line* no qual o usuário insere manualmente seus dados. Isso é feito apenas uma vez quando o usuário inicia o aplicativo de coleta de dados pela primeira vez e os dados coletados são a profissão (entrada de texto) e tem carro (escolha binária).

Para muitas tarefas, os atributos semânticos carregam informações significativas que complementam com eficiência os atributos básicos, como será demonstrado no Capítulo 6. Os valores dos atributos semânticos assumidos para esse trabalho são apresentados na Tabela 4.5. A categoria do POI foi concebido a partir dos POIs do *Google Places*, as profissões e a informação se possui carro foram colocadas de acordo com as informações dos usuários no experimento feito.

4.4 Geração do Classificador de HAR e Classificador de HAR

Os processos de geração do classificador de HAR e do classificador de HAR, apresentados na Figura 4.1, são similares nas fases de geração e execução. As técnicas e métricas utilizadas por eles são descritas a seguir.

Os processo de geração do classificador de HAR e classificador de HAR do MOut-

Tabela 4.5: Valores dos atributos semânticos.

Atributo	Valor
Categoria do POI	Educação Entretenimento Financeiro Comida Lei Religião Serviços Compras Transporte Outros
Profissão	Acadêmico Técnico administrativo Bancário Empresário Advogado Professor
Tem carro?	Sim Não

HAR foram combinados durante a implementação. De fato, ambos são realizados juntos por um processo de aprendizado de máquina que aprende a reconhecer atividades a partir dos *features* obtidos nas fases anteriores. Nesse processo foram utilizados seis algoritmos para extrair conhecimento dos dados e, em seguida, reconhecer as atividades: J48, *K-Nearest Neighbours* (KNN), *Multilayer Perceptrons* (MLP), *Naive Bayes* (NB), *Random Forests* (RF) e *Support Vector Machines* (SVM). Os algoritmos foram treinados e avaliados em termos de acurácia, precisão, *recall* e *f-measure* (veja Capítulo 6 para mais detalhes). Foi considerado que o processo de aprendizado forma a geração do classificador de HAR e o uso do modelo treinado abastece o processo do classificador de HAR para realizar o reconhecimento de atividades de novas instâncias.

4.5 Discussão

Esse Capítulo serviu para apresentar detalhadamente o modelo de reconhecimento de atividades humana proposto nesta tese (MOut-HAR). A Figura 4.1 mostrou o fluxograma do modelo para facilitar a compreensão das etapas executadas por ele. Inicialmente foi explicado o processo de sensoriamento, onde foi utilizado o sensor GPS com coleta de dados esparsa de 3 em 3 minutos. Logo em seguida, foi apresentada a etapa de processamento

de sinais, o objetivo foi demonstrar como os dados foram tratados e discretizados. Posteriormente, foi apresentada a etapa de extração de *features* e perfil do usuário, onde foram gerados dados semânticos para aumentar o nível de informação dos dados iniciais. E por último, foi apresentado o processo de geração do classificador de HAR e o classificador HAR, nesse processo é onde acontece o treinamento dos algoritmos e o reconhecimento de atividades propriamente dito, além da avaliação dos resultados através das métricas: acurácia, precisão, *recall* e *F-measure*.

Capítulo 5

HAR-Brazilian Dataset

Para esta tese foram pesquisados diversos datasets usados na tarefa de HAR. Foram encontrados datasets contendo dados de sensores e atividades variadas. Datasets usando dados de acelerômetro [7, 90] e GPS [60, 104] são os mais comuns.

O *dataset Real World* (HAR) [90] coletou dados de 15 pessoas durante 1065 minutos. Os sensores utilizados para a coleta foram: acelerômetro, GPS, giroscópio, luminosidade, magnético, som e câmera. As atividades registradas foram: subir e descer escadas, pular, deitar, parar em pé, sentar, correr e andar. Foram utilizados acelerômetros acoplados ao peito, antebraço, cabeça, canela, coxa, parte superior do braço e cintura.

O dataset apresentado por Anguita *et al.* [7] possui dados de acelerômetro e giroscópio de smartphones coletados a uma taxa de amostragem de 50Hz. O grupo de voluntários incluiu 30 pessoas de faixa etária entre 19 até 48 anos. Foram registradas 6 atividades diferentes: parado, sentado, deitado, andando, subindo escadas e descendo escadas. As atividades foram realizadas em condições de laboratório, mas os usuários tinham a liberdade de realizar livremente a sequência de atividades.

O *dataset GeoLife* [104] foi coletado de 178 usuários durante mais de 4 anos (de Abril de 2007 até Outubro de 2011). A trajetória do GPS deste *dataset* é representada por uma sequência de pontos com registro de data e hora, cada um contendo informações de latitude, longitude e altitude. Este conjunto de dados contém 17.621 trajetórias com uma distância total de 1.251.654 quilômetros e uma duração total de 48.203 horas. Essas trajetórias foram registradas por diferentes dispositivos de GPS e *smartphones* e com uma variedade de taxas de amostragem, 91% das trajetórias são registradas numa apresentação densa, por exemplo, a cada 1 à 5 segundos ou cada 5 à 10 metros por ponto. Esse conjunto de dados registrou uma ampla gama de movimentos ao livre dos usuários, incluindo não

apenas rotinas de vida como ir para casa ou ir para o trabalho, mas também, entretenimento, atividades esportivas, compras, passeios, restaurantes, caminhadas e ciclismo. Os trabalhos de usam

A base de dados *Weeplaces* [60] armazena as atividades de *check-in* dos usuários em Redes Sociais Baseadas em localização (*Local Based Social Networks* - LBSN). O sistema está integrado às APIs de outros serviços de LBSN, por exemplo, Facebook Places, Foursquare e Gowalla. Os usuários podem fazer o login no Weeplaces usando suas contas do LBSN e se conectar com seus amigos no mesmo LBSN que também usam esta rede social. Todos os dados coletados são originalmente gerados no *Foursquare*. Este conjunto de dados contém 7.658.368 *check-ins* gerados por 15.799 usuários em 971.309 locais diferentes. Os atributos disponibilizados e suas características são mostrados na Tabela 5.1.

Tabela 5.1: Atributos e características dos dados do *Weeplaces*.

Nome do Atributo	Características
<i>userid</i>	Nome de usuário cadastrado na LBSN
<i>placeid</i>	Nome do local do <i>check-in</i>
<i>datetim</i>	Data com dia, mês e ano e horário com hora minuto e segundo
<i>lat</i>	Latitude do local
<i>lon</i>	Longitude do local
<i>city</i>	Cidade onde foi feito o <i>check-in</i>
<i>category</i>	Categoria/atividade marcada no local

Esses *datasets* apresentados oferecem diferentes níveis de abstração para a tarefa de reconhecimento de atividades, apesar disso, nenhum deles apresentavam dados suficientes para suprir o modelo proposto. Com isso, foi necessário criar um novo *dataset* com todos os atributos necessários ao modelo. O primeiro passo para a criação do *dataset* foi criar uma ontologia simples para que a coleta de dados fosse eficiente e para ajudar a ter melhores resultados entendendo a relação entre os atributos. Após a criação da ontologia foi definida uma metodologia de coleta de dados, foi desenvolvido um aplicativo para coletar os dados necessário. Por fim, foi criado o *dataset* com as informações coletadas. O *dataset* foi dividido em dois subconjuntos, o primeiro foi uma coleta inicial para testes preliminares para verificar se a proposta era válida, os resultados estavam próximo do esperado. O segundo foi uma coleta mais robusta para verificar se a proposta conseguia o resultado esperado com uma variedade maior de dados.

5.1 Ontologia

O desenho da ontologia levou em consideração a revisão da literatura e a obtenção de conhecimento sobre o domínio obtido na primeira etapa de projeto. Todos os envolvidos no projeto foram entrevistados antes do experimento e um dos aspectos questionados foi o tipo de dados e conhecimentos que a ontologia deveria representar com o objetivo de cumprir a tarefa de reconhecimento de atividades.

Uma atividade fora de casa, como descrito na Figura 5.1, é um comportamento realizado por um indivíduo para realizar determinado propósito e com diversas características. A atividade ocorre em diversas configurações temporais e espaciais. Uma atividade faz parte de um fluxo de atividades. Onde, a Atividade A é uma atividade que é executada em uma velocidade Va , já uma atividade B é realizada em uma velocidade Vb e segue a atividade A . Sempre que Vb e Va são diferentes e uma delas é nula, uma transição de atividades é gerada; portanto, uma mudança de velocidade sugere/causa uma transição de atividade. Uma transição, embora ocorrida rapidamente, também faz parte do fluxo de atividades. A configuração temporal de uma determinada atividade é composta pelo horário inicial e final que causa (permite calcular) uma duração da atividade. Em termos de configuração espacial, a atividade é composta pela localização geográfica, definidas por suas coordenadas de longitude e latitude, e pelas informações relacionadas ao local, como o uso de POI. Os locais inicial e final levam/causam (permitem calcular) a distância percorrida (para atividades em movimento). Essa distância juntamente com a duração da atividades permitem calcular a velocidade média da atividade.

O fluxo de atividades representa o diário de atividades de uma pessoa com uma lista ordenada de atividades com duração, distância percorrida, velocidade média, local de início e de término, horário de início e término e POIs próximos. Esse diário também contém informações sobre o perfil do usuário, como a profissão e posse de carro e as propriedades dos dias, diferenciando os dias de semana úteis do fim de semana e feriado. As configurações temporais e espaciais, assim como os dados semânticos e o perfil do usuário, são usados para o reconhecimento de atividades. A proximidade do POI é a base para identificar uma possível atividade.




Figura 5.1: Ontologia para o reconhecimento de atividades fora de casa.

5.2 Metodologia de Coleta de Dados

Primeiro foi criado um projeto de coleta de dados seguindo os termos legais de ética e respeito a privacidade dos voluntários. O projeto criado foi enviado para o comitê de ética da universidade com o nome: “MobiVidade: Dados de Mobilidade para reconhecimento de atividades humanas”, sob a coordenação da professora Ana Cristina Bicharra Garcia. O segundo passo foi fazer o convite para estudantes da universidade e trabalhadores para participarem do experimento, foi enviado um resumo do projeto, termo de consentimento e foi pedido qual o sistema operacional dos *smartphones* dos voluntários, após isso, com a assinatura do termo, foi criado um aplicativo para *smartphones* Android para realizar a coleta de dados. O sistema operacional Android foi escolhido devido a maioria dos voluntários possuírem aparelhos com ele.

Cada voluntário instalou o aplicativo no seu *smartphone*, o aplicativo foi desenvolvido para coletar os dados brutos do GPS (latitude e longitude), a data e a hora do sistema a cada 3 minutos, tempo definido de acordo com a seção 4.1. A interface do usuário permite que o voluntário anote quando ele/ela inicia uma nova atividade. Como ilustrado na Figura 5.2, na parte esquerda mostra que o usuário deve associar um nome de usuário para identificação, identificação essa que se torna anônima na divulgação dos dados, e selecionar a atividade iniciada usando um *combo box* no campo atividade. Na Figura a direita é mostrado o *feedback* para o usuário indicando suas coordenadas GPS e sua




Figura 5.2: Interface do aplicativo desenvolvido para coleta de dados.

última atividade registrada. O botão Salvar salva as informações atualizadas, enquanto o botão Contato fornece informação de e-mail e número de telefone para comunicação com os desenvolvedores.

Após a instalação e as informações para o funcionamento do aplicativo, começou a coleta de dados. Todo o *log* de informações capturadas foram salvas em documentos de texto. O aplicativo fazia o *upload* do arquivo automaticamente todas as noites, eram feitos três tentativas de envio, uma as 23 horas, outra as 23 e 50 minutos e outra às 8 da manhã do outro dia. Foi pedido para os voluntários deixarem a internet ligada em pelo menos um dos três horários. Mensagens periódicas eram enviadas aos voluntários para lembrarem de atualizar as atividades e 10 minutos antes do horário de *upload*. O aplicativo coletou 13 atividades distintas, divididas em duas categorias, atividades de deslocamento e estacionárias, as atividades são apresentadas na Tabela 5.2.

5.3 HAR-Brazilian-RJ Dataset

O primeiro subconjunto de coleta de dados contou com voluntários de duas cidades do estado do Rio de Janeiro, foram elas Campos dos Goytacazes e Niterói. Inicialmente,

Tabela 5.2: Atividades reconhecidas nesta tese.

Tipo de atividade	Atividade
Deslocamento	Deslocamento a pé - Deslocamento de carro Deslocamento de ônibus
Estacionária	Almoçando - Comprando - Esperando transporte Estudando - Rezando - Jantando - No banco Recreação - Tomando café - Trabalhando

20 voluntários aceitaram fazer parte do projeto, porém só foram utilizados dados de 10 voluntários devido a problemas técnicos do aplicativo com a versão do Android que faziam com que gerassem *logs* sem informações do GPS.

Os 10 voluntários são de ambos os sexos e de idades entre 20 e 50 anos. Nesse subconjunto os dados de perfil quanto a profissão e se tem carro foram pedidos para o usuário diretamente. A quantificação e o perfil deles são apresentados na Tabela 5.3. Os dados foram coletados durante 10 dias no mês de novembro de 2016. Os participantes estavam envolvidos no ambiente acadêmico, como alunos, professores ou técnicos administrativos. O subconjunto HAR-Brazilian-RJ *dataset* contém 1.999 instâncias divididas conforme a Tabela 5.4.

Tabela 5.3: Distribuição do perfil dos voluntários do *dataset* HAR-Brazilian-RJ.

Profissão	Quantidade	Homem	Mulher	Tem carro	Não tem carro
Estudante	3	2	1	2	1
Professor	5	4	1	4	1
Técnico Administrativo	2	2	-	1	1
Total	10	8	2	7	3

5.4 HAR-Brazilian-MG Dataset

Para o segundo subconjunto de coleta de dados foram feitas atualizações no aplicativo para que não ocorressem os mesmos problemas do subconjunto anterior. O segundo contou com a participação de 22 voluntários de três cidades do estado de Minas Gerais, foram elas Lavras, Ituiutaba e Uberlândia. Quando o aplicativo era executado pela primeira vez pedia aos voluntários um preenchimento de um breve questionário de perfil com quatro questões: idade, sexo, profissão e se tem carro.

Os 22 voluntários são de ambos os sexos e de idades entre 18 a 56 anos. Nesse segundo subconjunto a maioria dos voluntários são do ambiente acadêmico, mas também houve

Tabela 5.4: Distribuição de instâncias das atividades no *dataset* HAR-Brazilian-RJ.

Atividade	Número de instâncias
Almoçando	238
Comprando	43
Deslocamento a pé	48
Deslocamento de carro	773
Deslocamento de ônibus	199
Esperando transporte	42
Estudando	97
Jantando	76
No banco	36
Recreação	30
Rezando	30
Tomando café	72
Trabalhando	315
Total	1.999

a participação de pessoas com outras profissões para ampliar a variabilidade dos dados, a distribuição e quantificação do perfil dos voluntários são apresentados na Tabela 5.5. Os dados foram coletados durante 20 dias nos meses de março e abril de 2018. É importante salientar que não houve abandono do experimento por parte dos voluntários e nem reclamações quanto a possibilidade do aumento significativo do consumo de bateria. O HAR-Brazilian-MG *dataset* é composto por 47.308 instâncias distribuídas de acordo com a Tabela 5.6.

Tabela 5.5: Distribuição do perfil dos voluntários do *dataset* HAR-Brazilian-MG.

Profissão	Quantidade	Homem	Mulher	Tem carro	Não tem carro
Advogado	2	1	1	2	-
Bancário	1	1	-	-	1
Empresário	1	1	-	1	-
Estudante	11	6	5	4	7
Professor	5	2	3	4	1
Técnico Administrativo	2	-	2	2	-
Total	22	11	11	13	9

A Tabela 5.7 ilustra quatro exemplos de instâncias do *dataset* HAR-Brazilian. As colunas um e dois indicam, respectivamente, o nome do atributo e seu tipo em relação à fonte de informação, é importante notar que o atributo na última linha da Tabela 5.7 (Atividade) é considerado como o objetivo da classificação (classe). As colunas três a cinco correspondem a exemplos coletados dos voluntários.

Tabela 5.6: Distribuição de instâncias das atividades no *dataset* HAR-Brazilian-MG.

Atividade	Número de instâncias
Almoçando	5.119
Comprando	1.629
Deslocamento a pé	1.378
Deslocamento de carro	14.110
Deslocamento de ônibus	6.774
Esperando transporte	804
Estudando	3.104
Jantando	1.939
No banco	903
Recreação	954
Rezando	986
Tomando café	1.152
Trabalhando	8.456
Total	47.308

Tabela 5.7: Exemplos (três exemplos) de instâncias do *HAR-Brazilian*.

Atributo	Tipo	Exemplo 1	Exemplo 2	Exemplo 3
Dia	Atributos básicos	Não Útil	Útil	Útil
Tempo inicial		Noite	Manhã	Tarde
Tempo Final		Noite	Tarde	Tarde
Duração		Longa	Longa	Baixa
Distância do ponto anterior	Atributos do GPS Enriquecidos	Nula	Nula	Longa
Velocidade		Nula	Nula	Média
Categoria do POI		Comida	Lei	Outros
Profissão	Atributos de perfil	Empresário	Advogado	Bancário
Tem carro?		Sim	Sim	Não
Atividade	Classe	Jantando	Trabalhando	Deslocamento de ônibus

5.5 Discussão

Mesmo existindo uma variedade de *datasets* de HAR, foi necessário criar um próprio para suprir as necessidades de atributos do modelo apresentado. Para isso, foi feito um estudo completo para a concepção do HAR-Brazilian *dataset*. A ontologia cooperou para facilitar o entendimento da relação dos atributos entre si e deles com a atividade. O desenvolvimento do aplicativo possibilitou o rápido acesso as informações e verificação e conserto de possíveis erros. Alguns trabalhos correlatos com características mais próximas do modelo apresentado nesta tese [28, 97] não disponibilizaram seus *datasets*, impossibilitando uma comparação direta entre eles. O *dataset* Weeplaces [60] possibilitou uma comparação parcial com o HAR-Brazilian.

Capítulo 6

Experimentos e Análise dos Resultados

Para validar o modelo proposto nesse trabalho foi necessário fazer diversos experimentos com diferentes configurações e algoritmos. Primeiro são apresentados os métodos de análise dos experimentos, com os algoritmos e métricas avaliados. Os experimentos foram divididos em quatro etapas. O experimento de sensibilidade foi feito para avaliar se os atributos utilizados tinham real relevância no resultado final. O experimento dos atributos foi feito para verificar a melhora dos resultados com a inserção de atributos nos testes. Esses primeiros experimentos foram feitos utilizando apenas o dataset HAR-Brazilian-MG. O terceiro experimento foi o teste treinando o algoritmo com o dataset HAR-Brazilian-MG e testando com HAR-Brazilian-RJ. E por fim, o experimento com o dataset Weeplaces foi feito para fazer uma comparação parcial do modelo apresentado com dados externos ao HAR-Brazilian dataset.

6.1 Métodos de Análise

A avaliação de desempenho da abordagem apresentada foi feita utilizando seis algoritmos de classificação diferentes. Mais especificamente, foram utilizadas as implementações do Weka¹ das seguintes técnicas, como as etapas de geração do classificador de HAR e classificador de HAR (seção 4.4) no modelo proposto: J48, MLP, SVM, RF, KNN e NB.

As métricas utilizadas para avaliar os resultados são: acurácia, precisão, *recall* e *F-measure*. Esses valores podem ser calculados a partir da matriz de confusão M , em que o elemento M_{ij} indica o número de instâncias da classe (atividade) A_i que foram classificadas como classe (atividade) A_j . Mais especificamente, as métricas acima mencionadas são

¹<http://www.cs.waikato.ac.nz/ml/weka/>

definidas como:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}, \quad (6.1)$$

$$\text{Precisão} = \frac{TP}{TP + FP}, \quad (6.2)$$

$$\text{Recall} = \frac{TP}{TP + FN}, \quad \text{e} \quad (6.3)$$

$$F\text{-measure} = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}}, \quad (6.4)$$

onde TP (True Positives - Verdadeiro Positivo) é o número de instâncias da atividade A_i corretamente classificada como A_i , TN (True Negatives - Verdadeiro Negativo) é o número de instâncias de atividade diferente de A_i classificadas como diferente de A_i , FP (False Positives - Falso Positivo) é o número de instâncias de atividades classificadas como A_i que não são atividades A_i , e FN (False Negatives - Falso Negativos) é o número de instâncias de atividades A_i não classificadas como atividades A_i .

6.2 Experimento de Sensibilidade

Um dos objetivos do modelo MOut-HAR é apresentar um conjunto minimalista de atributos, mas significativo, para obter o melhor resultado. O conjunto de atributos utilizados foi um número consideravelmente baixo (nove atributos). Outro questionamento sobre os atributos, é se os dados de perfil do usuário são eficientes na melhoria dos resultados. O experimento de sensibilidade visa verificar a eficiência desses atributos utilizados no resultado das classificações. Para todos os algoritmos foram feitos testes com apenas as atividades estáticas e com todas as atividades.

Para esse experimento foram utilizadas três técnicas de análise de sensibilidade dos atributos: *Correlation based Feature Selection*, *Information Gain based Feature Selection* e *Relief*. O *Correlation based Feature Selection* (CFS) é um algoritmo de filtragem simples que classifica subconjuntos de atributos de acordo com uma função de avaliação heurística baseada em correlação. O viés da função de avaliação é direcionado a subconjuntos que contêm recursos altamente correlacionados com a classe e não correlacionados entre si. Atributos irrelevantes deve ser ignorados, pois terão baixa correlação com a classe. Atributos redundantes devem ser filtrados, pois estarão altamente correlacionados com um ou mais dos demais atributos. A aceitação de um atributo dependerá da extensão para o qual prevê classes em áreas do espaço onde a instância ainda não prevista por outros atributo [42].

O *Information Gain based Feature Selection* (IG) é um algoritmo que calcula o ganho de informação (entropia) de cada atributo em relação as classes. Os atributos que contribuem com mais informações terão um valor maior de ganho de informações e podem ser selecionados, enquanto aqueles que não adicionam muita informação terão uma pontuação mais baixa e poderão ser removidos [9].

O algoritmo original *Relief* [55] foi formulado inspirado no aprendizado baseado em instância. É um método de seleção de atributos de filtragem de avaliação individual, o Relief calcula uma estatística para cada atributo que pode ser usada para estimar o atributo quanto a qualidade ou relevância para a classe desejada. Essas estatísticas de atributos são chamadas de pesos de atributo, ou mais casualmente como pontuações do atributo que podem variar de pior a melhor.

O algoritmo CFS utilizado para análise de sensibilidade dos atributos com as atividades estáticas apresenta um ranqueamento dos atributos com a maioria deles maior que 0,1, representando uma significância desses atributos em relação as classes, mesmo que mínima. Os atributos que ficaram com ranqueamento abaixo desse valor: Dist, Vel e Carro, são atributos fortemente relacionados as atividades de movimento. A Figura 6.1 demonstra o ranqueamento de todos os atributos. Quando o teste foi feito com todas as atividades, todos os atributos alcançaram ranqueamento no mínimo de 0,1. Os resultados desse segundo teste são apresentados na Figura 6.2.




Figura 6.1: Experimento de sensibilidade dos atributos pela técnica *Correlation based Feature Selection* com atividades estáticas.

A Figura 6.3 apresenta os resultados do uso da técnica IG com as atividades estáticas.




Figura 6.2: Experimento de sensibilidade dos atributos pela técnica *Correlation based Feature Selection* com todas as atividades.

Esses resultados demonstram que o atributo POI é o que carrega o maior ganho de informação, isso faz sentido, pois a maioria das atividades está fortemente vinculada a sua localização. Mais uma vez os três atributos característicos das atividades de movimento apareceram com o rankeamento baixo. A profissão teve seu rankeamento em 0,2 mostrando que pode ser um atributo importante para compor o perfil do usuário. Quando é feito o teste com todas as atividades apenas o atributo dia ficou com menos de 0,2 no rankeamento. A informação de ter carro, mesmo sendo uma informação binária chega a esse patamar de 0,2. A Figura 6.4 demonstra esses resultados.

O resultado do experimento de sensibilidade com o algoritmo *Relief* com as atividades estáticas é apresentado na Figura 6.5. Esses resultados apresentam o POI como o atributo com maior potencial com rankeamento próximo de 0,7, e em seguida, a profissão com o rankeamento próximo de 0,4, isso demonstra que para esse tipo de atividades a profissão é um atributo que pode melhorar os resultados. No teste com todas as atividades, somente o atributo carro ficou abaixo de 0,1 no rankeamento. Os resultados são demonstrados na Figura 6.6.

Os testes demonstraram uma variação de perspectiva dos atributos, onde com em cada algoritmo foi mudada a ordem do rankeamento dos atributos, mas mostrando que todos eles tem uma significância para a melhora do resultado final. Os testes não apresentaram unanimidade considerando um atributo ruim, com isso, foi decidido utilizar todos os atributos coletado, isso não é crítico, pois o número de atributos é reduzido (nove atributos)




Figura 6.3: Experimento de sensibilidade dos atributos pela técnica *Information Gain Based Feature Selection* com atividades estáticas.




Figura 6.4: Experimento de sensibilidade dos atributos pela técnica *Information Gain Based Feature Selection* com todas as atividades.

e dois deles são binários, ou seja, não necessitam de muito poder de processamento.




Figura 6.5: Experimento de sensibilidade dos atributos pela técnica *Relief* com atividades estáticas.




Figura 6.6: Experimento de sensibilidade dos atributos pela técnica *Relief* com todas as atividades.

6.3 Experimento dos Atributos

Um dos principais pontos do modelo MOut-HAR proposto é a caracterização do uso de atributos semânticos e do perfil do usuário. Para comprovar que o uso desses atributos é eficiente foi feito um experimento com três testes utilizando o *dataset* HAR-Brazilian-

MG. No primeiro teste foram utilizados apenas os atributos básicos e atributos do perfil do usuário. No segundo teste foram utilizados os atributos básicos e os atributos de GPS enriquecidos. E por fim, foram utilizados todos os atributos. Todos os testes foram feitos utilizando *10-fold cross-validation* e os algoritmos: J48, KNN, MLP, NB, RF e SVM.

Os resultados do primeiro teste são apresentados na Tabela 6.1. Eles correspondem a um cenário em que os atributos semânticos do GPS não são considerados. No entanto, é importante observar que esse cenário faz uso indireto das coordenadas GPS convencionais, pois o tempo de início/término e a duração de uma atividade são estimados em função do deslocamento do usuário no espaço. Portanto, pode-se associar o desempenho do sistema de HAR usando esse tipo limitado de dados ao desempenho de tentativas convencionais que seriam eficientes em termos de consumo de energia (ou seja, eles ainda estão executando leituras esparsas de um único sensor), mas fracas em termos de qualidade do reconhecimento de atividades. Nesse cenário, J48, KNN e RF apresentam os melhores resultados em todas as métricas avaliadas, mas todos os resultados são inferiores a 70% em termos de acurácia. Isso está longe dos resultados, com cerca de 90% de acurácia, apresentados por abordagens mais sofisticadas.

Tabela 6.1: Resultados do teste usando apenas os atributos básicos e perfil do usuário.

Algoritmo	Acertos	Erros	Acurácia	Precisão	Recall	F-Score
J48	31.716	15.592	0,670	0,684	0,670	0,658
KNN	31.710	15.598	0,670	0,684	0,670	0,658
MLP	31.133	16.175	0,658	0,663	0,658	0,647
NB	26.934	20.374	0,569	0,578	0,569	0,551
RF	31.705	15.603	0,670	0,685	0,670	0,658
SVM	30.308	17.000	0,641	0,630	0,640	0,622

O cenário do segundo teste incorpora explicitamente informações sobre o deslocamento do usuário (distância do ponto anterior e velocidade média) e a categoria do POI, mas não inclui dados do perfil do usuário. Como pode ser observado na Tabela 6.2, a contextualização fornecida pela informações enriquecidas do GPS leva melhorias que variam de 19% a 34% em termos de acurácia, 15% a 31% em termos de precisão, 19% a 34% em termos de *recall* e 16% a 34% em termos de *F-measure* em relação ao primeiro teste. J48, KNN e RF apresentaram os melhores resultados em todas as métricas avaliadas. Mesmo assim, o máximo de 80% de acurácia ainda está abaixo do que é apresentado na literatura.

No terceiro teste foram utilizados todos os atributos disponíveis. A Tabela 6.3 apresenta os resultados obtidos, onde houve uma melhoria significativa em todas as métricas avaliadas. A acurácia dos algoritmos J48 e KNN foi de 92,4%, resultado competitivo com

Tabela 6.2: Resultados do teste usando apenas os atributos básicos e atributos do GPS.

Algoritmo	Acertos	Erros	Acurácia	Precisão	Recall	F-Score
J48	37.822	9.486	0,799	0,791	0,799	0,785
KNN	37.830	9.478	0,800	0,792	0,800	0,786
MLP	37.539	9.769	0,793	0,784	0,794	0,777
NB	36.257	11.051	0,766	0,753	0,766	0,739
RF	37.822	9.486	0,799	0,791	0,799	0,786
SVM	36.955	10.353	0,781	0,755	0,781	0,723

o estado da arte. Isso mostra que a fusão dos atributos apresentados no modelo proposto, com apenas um único sensor, pode suprir a necessidade de mais sensores diminuindo o custo energético. A melhoria dos resultados em relação aos dois cenários anteriores fortifica a ideia de que se forem adicionados atributos simples, como os utilizado aqui, há uma possibilidade real de refinar modelos de HAR para atividades fora de casa.

Tabela 6.3: Resultados do teste usando todos os atributos.

Algoritmo	Acertos	Erros	Acurácia	Precisão	Recall	F-Score
J48	43.727	3.581	0,924	0,924	0,924	0,924
KNN	43.700	3.608	0,924	0,924	0,924	0,923
MLP	43.560	3.748	0,921	0,921	0,921	0,919
NB	39.931	7.377	0,844	0,845	0,844	0,840
RF	43.689	3.619	0,923	0,924	0,924	0,923
SVM	43.431	3.877	0,918	0,919	0,918	0,918

6.4 Experimento com o Dataset HAR-Brazilian-RJ

Todos os experimentos realizados anteriormente contaram com o uso apenas do *dataset* HAR-Brazilian-MG. Para esse experimento também foi utilizado o *dataset* HAR-Brazilian-RJ. Os testes foram feitos usando o HAR-Brazilian-MG para treinamento dos algoritmos e o HAR-Brazilian-RJ como teste. Esse experimento visa verificar a capacidade de generalização do modelo a partir do *dataset* de treino, aplicando-o em um conjunto de dados com pessoas e cidades diferentes. Os resultados desse experimento são apresentados na Tabela 6.4.

Os algoritmo J48, KNN, MLP, RF e SVM apresentaram resultados semelhantes para esse teste, com acurácia acima de 97%. A eficiência do conjunto de dados de treinamento é demonstrada através do *recall* e precisão, variando de 91,2% a 97,5%. A contextualização fornecida por dados de GPS enriquecidos e perfil do usuário torna os modelos de

Tabela 6.4: Resultados treinando com o *dataset* HAR-Brazilian-MG e testando com o HAR-Brazilian-RJ.

Algoritmo	Acertos	Erros	Acurácia	Precisão	Recall	F-Score
J48	1.949	50	0,975	0,975	0,975	0,974
KNN	1.949	50	0,975	0,975	0,975	0,974
MLP	1.949	50	0,975	0,975	0,975	0,974
NB	1.824	175	0,912	0,916	0,912	0,911
RF	1.949	50	0,975	0,975	0,975	0,974
SVM	1.947	52	0,974	0,974	0,974	0,973

classificação treinados resilientes a mudanças na população e até mesmo de cidades.

Com os resultados, é possível observar que a fusão de dados, nesse caso, trouxe melhores resultados do que usar uma única fonte de dados. Além disso, isso mostra que, para futuros aplicativos, os desenvolvedores não dependerão de um único método de classificação, pois os modelos testados apresentam resultados semelhantes. Os resultados da Tabela 6.4 (acima de 97%) indicam que os atributos enriquecidos utilizados no MOut-HAR podem gerar modelos robustos, conseguindo obter resultados de ponta mesmo quando for aplicado a pessoas diferentes de diferentes cidades.

6.5 Experimento com o Dataset Weeplaces

O *dataset* Weeplaces apresenta atributos básicos que permitiram uma comparação parcial com o HAR-Brazilian-MG. Algumas mudanças foram necessárias para que esse experimento ocorresse. Primeiro, foram utilizados apenas os atributos dia, tempo inicial, categoria do POI (através da latitude e longitude do Weeplaces) e categoria (atividade). Posteriormente, foi reduzida a dimensionalidade do *dataset* Weeplaces, pois haviam categorias que não se englobavam nas atividades reconhecidas pelo modelo proposto, além disso, foi necessário fazer a junção das atividades almoçando, jantando e tomando café para a atividade comendo. Após isso, restaram 4.227.821 instâncias distribuídas de acordo com a Tabela 6.5.

Para fazer a comparação com o *dataset* Weeplaces, foi utilizado o *dataset* HAR-Brazilian-MG como treino e testado com os dados do Weeplaces. A Tabela 6.6 mostra os resultados desse experimento. A diminuição do número de atividades e a junção de atividades refletem diretamente nos resultados. Os algoritmos J48 e RF apresentaram resultados acima de 90% em termos de acurácia, precisão e *recall*, isso mostra a capacidade de generalização do modelo proposto, podendo ter resultados competitivos mesmo com

Tabela 6.5: Distribuição de instâncias das atividades no *dataset* Weeplaces.

Atividade	Número de instâncias
Comendo	1.869.040
Comprando	850.263
Esperando transporte	50.592
Estudando	128.875
No banco	33.240
Recreação	659.559
Rezando	32.274
Trabalhando	603.978
Total	1.999

uma base completamente diferente e usando apenas alguns atributos básicos e a categoria do POI. O experimento da seção 6.3 fortalece a possibilidade de que o uso de todos os atributos do *dataset* HAR-Brazilian pode ajudar a tirar a ambiguidade de reconhecimento de algumas atividades e alcançar resultados ainda melhores.

Tabela 6.6: Resultados treinando com nosso *dataset* e testando com o *Weeplaces*.

Algoritmo	Acertos	Erros	Acurácia	Precisão	Recall	F-Score
J48	3.841.518	386.303	0,909	0,919	0,909	0,899
KNN	3.750.437	477.384	0,887	0,900	0,887	0,876
MLP	3.751.256	476.565	0,887	0,901	0,887	0,874
NB	3.820.165	407.656	0,904	0,913	0,904	0,894
RF	3.841.518	386.303	0,909	0,919	0,909	0,899
SVM	3.810.068	417.753	0,901	0,913	0,901	0,891

6.6 Discussão

Essa seção apresentou os experimentos feitos e os seus resultados. Também foram apresentados os métodos utilizados para analisar os resultados de cada um dos experimentos. Foram feitos quatro experimentos, o primeiro para analisar a sensibilidade dos atributos em relação às classes, com o objetivo de eliminar algum atributo que não gerasse ganho para o resultado final, após os testes foi decidido manter todos os atributos pré estabelecidos.

O segundo experimento foi um processo incremental onde foram utilizados três cenários começando com a utilização apenas dos atributos básicos, depois dos atributos básicos mais os atributos enriquecidos do GPS e, por último, utilizando todos os atributos, esse

experimento mostrou que é esperado que o uso dos atributos do *dataset* HAR-Brazilian podem ser agregados a qualquer modelo e alcançar uma melhoria nos resultados.

O terceiro experimento foi utilizando os dois *datasets* HAR-Brazilian-MG e RJ, utilizando o primeiro para treino e o segundo para teste, os resultados foram bastante promissores, mostrando que modelos baseados no *dataset* apresentado podem ser robustos e capazes de reconhecer atividades mesmo quando são pessoas diferentes e em diferentes cidades.

O último experimento foi para verificar o funcionamento de modelos baseados no *dataset* HAR-Brazilian-MG com um outro *dataset*, no caso o Weeplaces. Algumas adaptações foram necessárias para que uma comparação parcial pudesse ser feita. Apenas foi possível utilizar os atributos básicos e o POI, que estavam disponível no Weeplaces. Os resultados na casa dos 90% sugerem que o uso dos outros atributos pode melhorar ainda mais o refinamento dos modelos para reconhecer as atividades.

Capítulo 7

Conclusões e Trabalhos Futuros

Esta tese apresentou a abordagem MOut-HAR, cuja principal percepção é que o desempenho na tarefa de reconhecimento de atividades baseado apenas em dados de um único sensor (GPS) pode ser melhorado, enriquecendo as informações de posicionamento com informações semânticas do POI mais próximo e com poucas informações do perfil do usuário. Na abordagem apresentada, a fusão de dados é baseada no modelo *Waterfall* simplificado, e algoritmos de classificação prontos executam o reconhecimento de atividades.

Foram apresentados dois datasets: HAR-Brazilian-RJ e HAR-Brazilian-MG. O experimento do HAR-Brazilian-RJ ocorreu com a participação de 10 voluntários, das cidades de Niterói e Campos dos Goytacazes. O experimento do HAR-Brazilian-MG ocorreu com a participação de 22 voluntários, nas cidades de Lavras, Ituiutaba e Uberlândia. Os voluntários realizaram suas atividades de rotina, e foi incluso no dataset 10 atividades estacionárias e 3 atividades móveis. O enriquecimento semântico das amostras de GPS foi realizado através da identificação de POI mais próximo pelo *Google Places* e da anotação automática de sua disponibilidade associada. Os conjuntos de coletados para este trabalho são mais completos e têm mais variabilidade do que outros descritos na literatura.

Os resultados confirmaram as expectativas do modelo, mostrando que o desempenho de métodos de classificação convencionais como J48, SVM e RF é equivalente ao desempenho de algoritmos de última geração mais sofisticados, se as informações semânticas dos POIs e o perfil do usuário forem fundidas para poupar amostras de GPS ou de outros sensores. Da perspectiva do usuário, uma consequência vantajosa do uso não contínuo de um único senso do *smartphone* (somente GPS, coletado a cada três minutos) é a economia de bateria. Uma forte evidência a esse respeito é o fato de que, dos usuários inicialmente inscritos para a coleta de dados, não houve uma única reclamação sobre o consumo de energia e todos concluíram o experimento.

7.1 Contribuições da Pesquisa

Para auxiliar o acompanhamento das contribuições da pesquisa foi elaborada a Tabela 7.1, onde foi feita uma sumarização dos trabalhos relacionados e do MOut-HAR em termos das principais característica avaliadas. As contribuições foram divididas em minimalismo no uso de atributos, satisfação quanto ao consumo energético, abrangência do modelo e escalabilidade.

Tabela 7.1: Sumarização dos trabalhos relacionados. TR: Trabalhos relacionados, NV: Número de voluntários, DE: Duração do experimento (d=dias, mo=meses), TI: Intervalo de tempo entre os pontos de coleta de dados (em segundos, exceto [28] a cada 10 metros), NI: Número de instâncias, SI: Sensores usados para coletar informações, AS: Quantidade de atributos semânticos, NA: Número de atividades, e Resultados: A=acurácia, R=*recall*, P=precisão.

TR	NV	DE	TI	NI	SI	AS	NA	Resultados
Lee & Kwan [57]	36	–	0.2	$\sim 10^6$	Acel.+GPS	9	4	A:99%
Zhou <i>et al.</i> [105]	12	6 d	20	9,981	Acel.+GPS	–	5	A:94%
Shin <i>et al.</i> [87]	30	–	1	495	Acel.+GPS	–	4	A:82%
Wan & Lin [97]	1	121 d	15	366,291	GPS	3	–	A:91%
Zheng <i>et al.</i> [103]	65	10 mo	–	–	GPS	9	4	R:76% P:76%
Van Dijk [94]	–	–	30-60	345,000	GPS	16	2	A:99%
Liao <i>et al.</i> [59]	4	–	60	10,000	GPS	4	7	A:90%
Huang <i>et al.</i> [49]	10	–	–	8,089	GPS	3	6	A:70%–100%
Boukhechba <i>et al.</i> [14]	1	–	5-10	1,368	GPS	3	6	–
Difrancesco <i>et al.</i> [28]	5	5 d	(10 m)	–	GPS	2	6	R:78% P:95%
MOut-HAR	22	20 d	180	47,308	GPS	3	13	A:92–97%

7.1.1 Minimalismo no Uso de Atributos

O modelo apresentado tem como base o uso de nove atributos, porém a maioria dos atributos utilizados não necessita de uma alta utilização de recursos para ser adquirido e processado, por exemplo, o atributo tem carro? e dia são binários, e além disso, são informações recebidas diretamente da fonte. O minimalismo no uso de atributos está diretamente ligado ao custo computacional em relação aos resultados. Nesta tese não foi dedicada nenhuma métrica para avaliar esse custo computacional, porém foram feitos teste de sensibilidade correlacionando os atributos com as classes, e nenhum deles foi descartado devido sua importância para melhorar a classificação.

Os atributos que geram maior carga são os atributos semânticos representados na Tabela 7.1 na coluna AS. O número de atributos semânticos utilizados neste modelo foram três, ficando atrás apenas do trabalho [28], porém como o minimalismo deve também

atender aos resultados, o número de atividades do modelo MOut-HAR é o dobro e os resultados são competitivos.

7.1.2 Satisfação Quanto ao Consumo Energético

Os trabalhos existentes diferem em relação aos sensores usados. As atividades internas são suportadas não apenas por *smartphones*, mas também por uma variedade de sensores incorporados no ambiente, como captura de vídeo (por exemplo, [66, 106]) e RFID (por exemplo, [73]). As atividades ao ar livre contam com uma variedade de sensores de dispositivos móveis, como acelerômetros, GPS, luminosidade, som, etc. Em alguns casos, também podem ser usados sensores vestíveis. A maioria dos pesquisadores utilizam GPS e acelerômetro (veja a coluna SI na Tabela 7.1). O modelo apresentado considera apenas informações de GPS, o fornecimento de informações do perfil do usuário obtidas e a categoria do POI aumentam a capacidade de reconhecimento de atividades, resolvendo muitas ambiguidades de informações.

O cronograma de aquisição de dados tem um impacto direto no uso de energia. Frequentemente, a aquisição de dados a partir de sensores é realizada continuamente em intervalos mínimos de tempo (por exemplo, [14, 57, 87, 97, 105]) sem contabilizar o consumo de energia necessário. O modelo apresentado considerou o consumo energético como um problema na coleta de dados, por isso foram testados diferentes intervalos de coleta em relação ao consumo da bateria e a perda de dados. O resultado do teste demonstrou que a coleta de dados a cada três minutos poderia ser eficiente, esse intervalo de tempo foi projetado após testar o equilíbrio entre a vivacidade dos dados e a precisão da localização, por um lado, e o consumo de energia do GPS e a perda de dados, por outro. Veja a coluna TI na Tabela 7.1 .

7.1.3 Abrangência do Modelo

Os resultados de *recall* fortalecem a capacidade do modelo de reconhecer um número considerável de atividades. Existem soluções que reconhecem poucos (por exemplo, [51]), muitos (por exemplo, [28, 50]), ou mesmo para cobrir qualquer tipo de atividade (por exemplo, [59]) geralmente de uma maneira muito abstrata. Em termos de contexto, classificamos as atividades em *scripts* e em contexto aberto. Alguns trabalhos possuem usuários que executam um *script* de atividades predefinidas por um curto período de tempo (por exemplo, [71, 82]), enquanto em outros trabalhos os usuários fazem suas

atividades diárias por um longo período de tempo (por exemplo, [59]). Os *datasets* usados nesta tese foram produzidos em um contexto aberto e no mundo real, com um conjunto de 13 atividades, embora esse número não seja uma restrição. A coluna NA da Tabela 7.1 demonstra o número de atividades nos diversos trabalhos da literatura.

7.1.4 Escalabilidade

O número de voluntários considerados no experimento é importante para refletir a robustez do modelo de reconhecimento de atividades para processar dados heterogêneos dos diversos usuários. Cada voluntário fornece um conjunto de dados independente que é coletado e usado para o reconhecimento de atividades. Existem modelos que foram gerados com a observação de um único usuário (por exemplo, [68]), poucos usuários (até cinco, por exemplo, [28, 59]) ou de um grande grupo de usuários (mais de dez, por exemplo, [82]). Quanto maior o número de voluntários observados, mais confiável é o modelo e melhores são as chances de reproduzir e ampliar a solução. Nesta tese, foram usados dados coletados de 22 usuários durante 20 dias, veja a coluna NV na Tabela 7.1.

O experimento com os dados do Weeplaces também permite mostrar a capacidade de escalabilidade do modelo apresentado, mesmo com dados de pessoas com culturas e países diferentes, e ainda sem a possibilidade de utilizar todos os atributos, foi possível alcançar uma acurácia acima de 90%.

7.2 Limitações

Esta tese descreveu um modelo minimalista para reconhecimento de atividades humanas, porém o modelo possui algumas limitações. O modelo é dependente do bom funcionamento do sensor GPS, ou seja, se esses dados não estiverem disponíveis ou não estiverem calibrados, os resultados não serão eficientes. Além disso, o modelo também é dependente da rotina das pessoas, isso se torna evidente, pois se as pessoas não tem um padrão de comportamento e atividades, os algoritmos não serão capazes de formular classificações consistentes.

Outra limitação desta pesquisa é em termos do modelo reconhecer apenas atividades fora de casa. A maioria das atividades reconhecidas tem forte ligação com o local no qual ela é realizada, a única informação que foi captada era que a pessoa estava em casa. Diversas atividades são realizadas dentro de casa, porém para que seja possível o reconhecimento delas são necessários sensores que captam os movimentos das pessoas.

7.3 Trabalhos Futuros

Um possível desdobramento para trabalhos futuros é a adição de outros atributos do perfil do usuário com menor latência e a detecção de atividades sazonais (por exemplo, atividades de inverno ou de verão). A capacidade de detecção do modelo proposto pode beneficiar abordagens semi-supervisionadas, como a de Levatić *et al.* [58], associando automaticamente categorias orientadas a atividades a POIs desconhecidos.

Outro desdobramento possível é explorar a possibilidade de integração do modelo apresentado com representações não determinísticas de sequências de atividades, como Modelos Ocultos de Markov, por exemplo. Outras pesquisas podem explorar a integração e implementação do módulo de tomada de decisão, no nível 3 do fluxograma do modelo *Waterfall* (veja a Figura 4.2), criando aplicativos que desencadeiam ações. Eles podem ser particularmente úteis para *assisted living*, informando e alertando o usuário ou uma equipe de suporte ao usuário.

Esse modelo proposto abre a possibilidade de usar dados legados para executar o HAR, desde que as informações semânticas necessárias possam ser associadas a esses dados. Por outro lado, este trabalho também deve ter uma reflexão sobre seus usos indevidos, como vigilância e controle da população. É uma área em que a necessidade de políticas públicas para estabelecer regulamentos estritos sobre o *design* e a auditoria é altamente rigorosa.

Referências

- [1] AHER, S. B.; LOBO, L. Comparative study of classification algorithms. *International Journal of Information Technology* 5, 2 (2012), 239–243.
- [2] ALLEN, J. F. Maintaining knowledge about temporal intervals. In *Readings in qualitative reasoning about physical systems*. Elsevier, 1990, pp. 361–372.
- [3] ALTUN, K.; BARSHAN, B.; TUNÇEL, O. Comparative study on classifying human activities with miniature inertial and magnetic sensors. *Pattern Recognition* 43, 10 (2010), 3605–3620.
- [4] AMATO, G.; STRACCIA, U. User profile modeling and applications to digital libraries. In *International Conference on Theory and Practice of Digital Libraries* (1999), Springer, pp. 184–197.
- [5] ANDROID. *ActivityRecognitionClient*, acessado em 30 de Abril de 2019.
- [6] ANDROID_DEVELOPERS. Sensors overview, 2013. Disponível em http://developer.android.com/guide/topics/sensors/sensors_overview.html.
- [7] ANGUIITA, D.; GHIO, A.; ONETO, L.; PARRA, X.; REYES-ORTIZ, J. L. A public domain dataset for human activity recognition using smartphones. In *Esann* (2013).
- [8] APPLE. *CMMotionActivity*, acessado em 30 de Abril de 2019.
- [9] AZHAGUSUNDARI, B.; THANAMANI, A. S. Feature selection based on information gain. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)* 2, 2 (2013), 18–21.
- [10] BAO, L.; INTILLE, S. S. Activity recognition from user-annotated acceleration data. In *International Conference on Pervasive Computing* (2004), Springer, pp. 1–17.
- [11] BARAL, R.; LI, T. Exploiting the roles of aspects in personalized poi recommender systems. *Data Mining and Knowledge Discovery* 32, 2 (2018), 320–343.
- [12] BEN KHALIFA, M.; REDONDO, R. P. D.; VILAS, A. F.; RODRÍGUEZ, S. S. Identifying urban crowds using geo-located social media data: a twitter experiment in new york city. *Journal of Intelligent Information Systems* 48, 2 (2017), 287–308.
- [13] BHARTI, P.; DE, D.; CHELLAPPAN, S.; DAS, S. K. Human: Complex activity recognition with multi-modal multi-positional body sensing. *IEEE Transactions on Mobile Computing* (2018).

- [14] BOUKHECHBA, M.; BOUZOUANE, A.; BOUCHARD, B.; GOUIN-VALLERAND, C.; GIROUX, S. Online recognition of people's activities from raw gps data: semantic trajectory data analysis. In *Proceedings of the 8th ACM International Conference on Pervasive Technologies Related to Assistive Environments* (2015), ACM, p. 40.
- [15] CAO, L.; WANG, Y.; ZHANG, B.; JIN, Q.; VASILAKOS, A. V. Gchar: An efficient group-based context—aware human activity recognition on smartphone. *Journal of Parallel and Distributed Computing* 118 (2018), 67–80.
- [16] CARROLL, A.; HEISER, G., ET AL. An analysis of power consumption in a smartphone. In *USENIX annual technical conference* (2010), vol. 14, Boston, MA, pp. 21–21.
- [17] CHAMROUKHI, F.; MOHAMMED, S.; TRABELSI, D.; OUKHELLOU, L.; AMIRAT, Y. Joint segmentation of multivariate time series with hidden process regression for human activity recognition. *Neurocomputing* 120 (2013), 633–644.
- [18] CHEN, H.; FININ, T.; JOSHI, A. The soupa ontology for pervasive computing. In *Ontologies for agents: Theory and experiences*. Springer, 2005, pp. 233–258.
- [19] CHEN, L.; NUGENT, C. Ontology-based activity recognition in intelligent pervasive environments. *International Journal of Web Information Systems* (2009).
- [20] CHON, J.; CHA, H. Lifemap: A smartphone-based context provider for location-based services. *IEEE Pervasive Computing* 10, 2 (2011), 58–67.
- [21] CHRISTIN, D.; REINHARDT, A.; KANHERE, S. S.; HOLLICK, M. A survey on privacy in mobile participatory sensing applications. *Journal of Systems and Software* 84, 11 (2011), 1928–1946.
- [22] COVER, T. M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *IEEE transactions on electronic computers*, 3 (1965), 326–334.
- [23] DA PENHA NATAL, I. Modelo de reconhecimento de atividades baseados em dados de gps e contexto de trajetórias. In *Workshop de Pesquisa e Desenvolvimento em Inteligência Artificial, Inteligência Coletiva e Ciência de Dados* (2016).
- [24] DA PENHA NATAL, I.; CORDEIRO, R. D. A. C.; GARCIA, A. C. B. Activity recognition model based on gps data, points of interest and user profile. In *International Symposium on Methodologies for Intelligent Systems* (2017), Springer, pp. 358–367.
- [25] DA PENHA NATAL, I.; CORREIA, L.; GARCIA, A. C.; FERNANDES, L. Efficient out-of-home activity recognition by complementing gps data with semantic information. *First Monday* 24, 11 (2019).
- [26] DAO, M.-S.; NGUYEN-GIA, T.-A.; MAI, V.-C. Daily human activities recognition using heterogeneous sensors from smartphones. *Procedia computer science* 111 (2017), 323–328.
- [27] DE, D.; BHARTI, P.; DAS, S.; CHELLAPPAN, S. Multi-modal wearable sensing for fine-grained activity recognition in healthcare. *IEEE Internet Computing*, 1 (2015), 1–1.

- [28] DIFRANCESCO, S.; FRACCARO, P.; VAN DER VEER, S. N.; ALSHOUMR, B.; AINSWORTH, J.; BELLAZZI, R.; PEEK, N. Out-of-home activity recognition from gps data in schizophrenic patients. In *2016 IEEE 29th International Symposium on Computer-Based Medical Systems (CBMS)* (2016), IEEE, pp. 324–328.
- [29] DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern classification*. John Wiley & Sons, 2012.
- [30] EL HAJJ, W.; BRAHIM, G. B.; EL-HAYEK, C.; HAJJ, H. Feature extraction and large activity-set recognition using mobile phone sensors. In *Data Science–Analytics and Applications*. Springer, 2017, pp. 65–70.
- [31] ESTEBAN, J.; STARR, A.; WILLETTS, R.; HANNAH, P.; BRYANSTON-CROSS, P. A review of data fusion models and architectures: towards engineering guidelines. *Neural Computing & Applications* 14, 4 (2005), 273–281.
- [32] FGV, F. G. V. 30^a pesquisa anual do fgvcia da fgv/eaesp, 2019: Mercado brasileiro de ti e uso nas empresas, 2019. Disponível em https://eaesp.fgv.br/sites/eaesp.fgv.br/files/noticias2019fgvcia_2019.pdf.
- [33] FOERSTER, F.; SMEJA, M.; FAHRENBERG, J. Detection of posture and motion by accelerometry: a validation study in ambulatory monitoring. *Computers in Human Behavior* 15, 5 (1999), 571–583.
- [34] FOX, M. S.; BARBUCEANU, M.; GRUNINGER, M. An organisation ontology for enterprise modelling: preliminary concepts for linking structure and behaviour. In *Enabling Technologies: Infrastructure for Collaborative Enterprises, 1995., Proceedings of the Fourth Workshop on* (1995), IEEE, pp. 71–81.
- [35] FRANK, K.; RÖCKL, M.; NADALES, M. J. V.; ROBERTSON, P.; PFEIFER, T. Comparison of exact static and dynamic bayesian context inference methods for activity recognition. In *Pervasive Computing and Communications Workshops (PERCOM Workshops), 2010 8th IEEE International Conference on* (2010), IEEE, pp. 189–195.
- [36] FURLETTI, B.; CINTIA, P.; RENSO, C.; SPINSANTI, L. Inferring human activities from gps tracks. In *Proceedings of the 2nd ACM SIGKDD International Workshop on Urban Computing* (2013), ACM, p. 5.
- [37] GIBSON, J. J. *The Ecological Approach to Visual Perception*. Houghton Mifflin, 1979.
- [38] GOMES, J. B.; KRISHNASWAMY, S.; GABER, M. M.; SOUSA, P. A.; MENASALVAS, E. Mars: a personalised mobile activity recognition system. In *2012 IEEE 13th International Conference on Mobile Data Management* (2012), IEEE, pp. 316–319.
- [39] GU, F.; KHOSHELHAM, K.; VALAEE, S.; SHANG, J.; ZHANG, R. Locomotion activity recognition using stacked denoising autoencoders. *IEEE Internet of Things Journal* 5, 3 (2018), 2085–2093.
- [40] GUPTA, P.; DALLAS, T. Feature selection and activity recognition system using a single triaxial accelerometer. *IEEE Transactions on Biomedical Engineering* 61, 6 (2014), 1780–1786.

- [41] HALL, D. L.; LLINAS, J. An introduction to multisensor data fusion. *Proceedings of the IEEE* 85, 1 (1997), 6–23.
- [42] HALL, M. A. Correlation-based feature selection for machine learning. *Doctoral dissertation, University of Waikato, Dept. of Computer Science* (1999).
- [43] HANAI, Y.; NISHIMURA, J.; KURODA, T. Haar-like filtering for human activity recognition using 3d accelerometer. In *Digital Signal Processing Workshop and 5th IEEE Signal Processing Education Workshop, 2009. DSP/SPE 2009. IEEE 13th* (2009), IEEE, pp. 675–678.
- [44] HASSAN, M. M.; UDDIN, M. Z.; MOHAMED, A.; ALMOGREN, A. A robust human activity recognition system using smartphone sensors and deep learning. *Future Generation Computer Systems* 81 (2018), 307–313.
- [45] HE, Z.; JIN, L. Activity recognition from acceleration data based on discrete cosine transform and svm. In *Systems, Man and Cybernetics, 2009. SMC 2009. IEEE International Conference on* (2009), IEEE, pp. 5041–5044.
- [46] HE, Z.; LIU, Z.; JIN, L.; ZHEN, L.-X.; HUANG, J.-C. Weightlessness feature—a novel feature for single tri-axial accelerometer based activity recognition. In *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on* (2008), IEEE, pp. 1–4.
- [47] HE, Z.-Y.; JIN, L.-W. Activity recognition from acceleration data using ar model representation and svm. In *Machine Learning and Cybernetics, 2008 International Conference on* (2008), vol. 4, IEEE, pp. 2245–2250.
- [48] HUANG, K. L.; KANHERE, S. S.; HU, W. Preserving privacy in participatory sensing systems. *Computer Communications* 33, 11 (2010), 1266–1280.
- [49] HUANG, L.; LI, Q.; YUE, Y. Activity identification from gps trajectories using spatial temporal pois’ attractiveness. In *Proceedings of the 2nd ACM SIGSPATIAL International Workshop on location based social networks* (2010), ACM, pp. 27–30.
- [50] HUANG, W.; LI, M.; HU, W.; SONG, G.; XING, X.; XIE, K. Cost sensitive gps-based activity recognition. In *2013 10th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)* (2013), IEEE, pp. 962–966.
- [51] HUNG, W.-C.; SHEN, F.; WU, Y.-L.; HOR, M.-K.; TANG, C.-Y. Activity recognition with sensors on mobile devices. In *Proc. International Conference on Machine Learning and Cybernetics (ICMLC)* (2014), vol. 2, IEEE, pp. 449–454.
- [52] IGNATOV, A. Real-time human activity recognition from accelerometer data using convolutional neural networks. *Applied Soft Computing* 62 (2018), 915–922.
- [53] KIM, D. I.; MARTINSON, E. Human centric spatial affordances for improving human activity recognition. In *Intelligent Robots and Systems (IROS), 2016 IEEE/RSJ International Conference on* (2016), IEEE, pp. 725–730.
- [54] KIM, E.; HELAL, S.; COOK, D. Human activity recognition and pattern discovery. *IEEE Pervasive Computing/IEEE Computer Society [and] IEEE Communications Society* 9, 1 (2010), 48.

- [55] KIRA, K.; RENDELL, L. A., ET AL. The feature selection problem: Traditional methods and a new algorithm. In *Aaai* (1992), vol. 2, pp. 129–134.
- [56] LEE, B.; LIM, C.; LEE, K. Classification of indoor-outdoor location using combined global positioning system (gps) and temperature data for personal exposure assessment. *Environmental Health and Preventive Medicine* 22, 1 (2017), 29.
- [57] LEE, K.; KWAN, M.-P. Physical activity classification in free-living conditions using smartphone accelerometer data and exploration of predicted results. *Computers, Environment and Urban Systems* 67 (2018), 124–131.
- [58] LEVATIĆ, J.; CECI, M.; KOCEV, D.; DŽEROSKI, S. Semi-supervised classification trees. *Journal of Intelligent Information Systems* 49, 3 (2017), 461–486.
- [59] LIAO, L.; FOX, D.; KAUTZ, H. Location-based activity recognition. In *Advances in Neural Information Processing Systems* (2006), pp. 787–794.
- [60] LIU, Y.; WEI, W.; SUN, A.; MIAO, C. Exploiting geographical neighborhood characteristics for location recommendation. In *Proceedings of the 23rd ACM International Conference on Conference on Information and Knowledge Management* (2014), ACM, pp. 739–748.
- [61] LLINAS, J.; HALL, D. L. An introduction to multi-sensor data fusion. In *Circuits and Systems, 1998. ISCAS'98. Proceedings of the 1998 IEEE International Symposium on* (1998), vol. 6, IEEE, pp. 537–540.
- [62] LOH, W.-Y. Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* 1, 1 (2011), 14–23.
- [63] MANDIC, D. P.; OBRADOVIC, D.; KUH, A.; ADALI, T.; TRUTSCHELL, U.; GOLZ, M.; DE WILDE, P.; BARRIA, J.; CONSTANTINIDES, A.; CHAMBERS, J. Data fusion for modern engineering applications: An overview. In *International Conference on Artificial Neural Networks* (2005), Springer, pp. 715–721.
- [64] MARKIN, M.; HARRIS, C.; BERNHARDT, M.; AUSTIN, J.; BEDWORTH, M.; GREENWAY, P.; JOHNSTON, R.; LITTLE, A.; LOWE, D. Technology foresight on data fusion and data processing. *The royal aeronautical society* (1997).
- [65] MAURER, U.; SMAILAGIC, A.; SIEWIOREK, D. P.; DEISHER, M. Activity recognition and monitoring using multiple sensors on different body positions. In *Wearable and Implantable Body Sensor Networks, 2006. BSN 2006. International Workshop on* (2006), IEEE, pp. 4–pp.
- [66] MITCHELL, D.; MORROW, P. J.; NUGENT, C. D. A sensor and video based ontology for activity recognition in smart environments. In *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (Aug 2014), pp. 5932–5935.
- [67] MOENCKS, M.; DE SILVA, V.; ROCHE, J.; KONDOZ, A. Adaptive feature processing for robust human activity recognition on a novel multi-modal dataset. *arXiv preprint arXiv:1901.02858* (2019).

- [68] MOUSAVI, A.; SHEIKH MOHAMMAD ZADEH, A.; AKBARI, M.; HUNTER, A. A new ontology-based approach for human activity recognition from gps data. *Journal of AI and Data Mining* 5, 2 (2017), 197–210.
- [69] MUKHOPADHYAY, S. C. Wearable sensors for human activity monitoring: A review. *IEEE sensors journal* 15, 3 (2015), 1321–1330.
- [70] NEBEL, B.; BÜRCKERT, H.-J. Reasoning about temporal relations: a maximal tractable subclass of allen’s interval algebra. *Journal of the ACM (JACM)* 42, 1 (1995), 43–66.
- [71] NOOR, M. H. M.; SALCIC, Z.; KEVIN, I.; WANG, K. Enhancing ontological reasoning with uncertainty handling for activity recognition. *Knowledge-Based Systems* 114 (2016), 47–60.
- [72] OGBUABOR, G.; LA, R. Human activity recognition for healthcare using smartphones. In *Proceedings of the 2018 10th International Conference on Machine Learning and Computing* (2018), ACM, pp. 41–46.
- [73] PARK, S.; KAUTZ, H. Hierarchical recognition of activities of daily living using multi-scale, multi-perspective vision and rfid. In *Intelligent Environments, 2008 IET 4th International Conference on* (2008), IET, pp. 1–4.
- [74] PARKKA, J.; ERMES, M.; KORPIA, P.; MANTYJARVI, J.; PELTOLA, J.; KORHONEN, I. Activity classification using realistic data from wearable sensors. *IEEE Transactions on information technology in biomedicine* 10, 1 (2006), 119–128.
- [75] PATTERSON, D. J.; FOX, D.; KAUTZ, H.; PHILIPPOSE, M. Fine-grained activity recognition by aggregating abstract object usage. In *Ninth IEEE International Symposium on Wearable Computers (ISWC’05)* (Oct 2005), pp. 44–51.
- [76] PHILIPPOSE, M.; FISHKIN, K. P.; PERKOWITZ, M.; PATTERSON, D. J.; FOX, D.; KAUTZ, H.; HAHNEL, D. Inferring activities from interactions with objects. *IEEE Pervasive Computing* 3, 4 (Oct 2004), 50–57.
- [77] PREUVENEERS, D.; DEN BERGH, J. V.; WAGELAAR, D.; GEORGES, A.; RIGOLE, P.; CLERCKX, T.; BERBERS, Y.; CONINX, K.; JONCKERS, V.; BOSSCHERE, K. D. Towards an extensible context ontology for ambient intelligence. In *Second European Symposium on Ambient Intelligence* (Eindhoven, The Netherlands, Nov 8 – 11 2004), P. Markopoulos, B. Eggen, E. Aarts, and J. L. Crowley, Eds., vol. 3295 of *LNCS*, Springer, pp. 148 – 159.
- [78] RABINER, L. R. A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE* 77, 2 (1989), 257–286.
- [79] RANASINGHE, S.; AL MACHOT, F.; MAYR, H. C. A review on applications of activity recognition systems with regard to performance and evaluation. *International Journal of Distributed Sensor Networks* 12, 8 (2016), 1550147716665520.
- [80] REDDY, S.; MUN, M.; BURKE, J.; ESTRIN, D.; HANSEN, M.; SRIVASTAVA, M. Using mobile phones to determine transportation modes. *ACM Transactions on Sensor Networks (TOSN)* 6, 2 (2010), 13.

- [81] RIBEIRO, P. C.; SANTOS-VICTOR, J.; LISBOA, P. Human activity recognition from video: modeling, feature selection and classification architecture. In *Proceedings of International Workshop on Human Activity Recognition and Modelling* (2005), Citeseer, pp. 61–78.
- [82] RIBONI, D.; BETTINI, C. Cosar: hybrid reasoning for context-aware activity recognition. *Personal and Ubiquitous Computing* 15, 3 (2011), 271–289.
- [83] RODRÍGUEZ, N. D.; CUÉLLAR, M. P.; LILIUS, J.; CALVO-FLORES, M. D. A fuzzy ontology for semantic modelling and recognition of human behaviour. *Know.-Based Syst.* 66, 1 (Aug. 2014), 46–60.
- [84] RUMELHART, D. E.; MCCLELLAND, J. L.; GROUP, P. R., ET AL. Parallel distributed processing: Explorations in the microstructures of cognition. volume 1: Foundations, 1986.
- [85] SCHÖLKOPF, B.; SMOLA, A. J. *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT press, 2002.
- [86] SHAFIQUE, M.; HATO, E. Travel mode detection with varying smartphone data collection frequencies. *Sensors* 16, 5 (2016), 716.
- [87] SHIN, D.; ALIAGA, D.; TUNÇER, B.; ARISONA, S. M.; KIM, S.; ZÜND, D.; SCHMITT, G. Urban sensing: Using smartphones for transportation mode classification. *Computers, Environment and Urban Systems* 53 (2015), 76–86.
- [88] SOUSA, W.; SOUTO, E.; RODRIGUES, J.; SADARC, P.; JALALI, R.; EL-KHATIB, K. A comparative analysis of the impact of features on human activity recognition with smartphone sensors. In *Proceedings of the 23rd Brazilian Symposium on Multimedia and the Web* (2017), ACM, pp. 397–404.
- [89] SUBETHA, T.; CHITRAKALA, S. A survey on human activity recognition from videos. In *2016 International Conference on Information Communication and Embedded Systems (ICICES)* (2016), IEEE, pp. 1–7.
- [90] SZTYLER, T.; STUCKENSCHMIDT, H. On-body localization of wearable devices: An investigation of position-aware activity recognition. In *2016 IEEE International Conference on Pervasive Computing and Communications (PerCom)* (2016), IEEE Computer Society, pp. 1–9. <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=7456521>.
- [91] TAPIA, E. M.; INTILLE, S. S.; HASKELL, W.; LARSON, K.; WRIGHT, J.; KING, A.; FRIEDMAN, R. Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart monitor. In *In: Proc. Int. Symp. on Wearable Comp* (2007), Citeseer.
- [92] THEODORIDIS, S.; PIKRAKIS, A.; KOUTROUMBAS, K.; CAVOURAS, D. *Introduction to pattern recognition: a matlab approach*. Academic Press, 2010.
- [93] TRABELSI, D.; MOHAMMED, S.; CHAMROUKHI, F.; OUKHELLOU, L.; AMIRAT, Y. An unsupervised approach for automatic activity recognition based on hidden markov model regression. *IEEE Transactions on Automation Science and Engineering* 10, 3 (2013), 829–835.

- [94] VAN DIJK, J. Identifying activity-travel points from gps-data with multiple moving windows. *Computers, Environment and Urban Systems* 70 (2018), 84–101.
- [95] VAPNIK, V. *The nature of statistical learning theory*. Springer science & business media, 2013.
- [96] VERGARA-LAURENS, I. J.; LABRADOR, M. A. Preserving privacy while reducing power consumption and information loss in lbs and participatory sensing applications. In *GLOBECOM Workshops (GC Wkshps), 2011 IEEE* (2011), IEEE, pp. 1247–1252.
- [97] WAN, N.; LIN, G. Life-space characterization from cellular telephone collected gps data. *Computers, Environment and Urban Systems* 39 (2013), 63–70.
- [98] WEBB, A. R. *Statistical pattern recognition*. John Wiley & Sons, 2003.
- [99] WITTEN, I. H.; FRANK, E.; HALL, M. A.; PAL, C. J. *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2016.
- [100] XIE, L.; TIAN, J.; DING, G.; ZHAO, Q. Human activity recognition method based on inertial sensor and barometer. In *Inertial Sensors and Systems (INERTIAL), 2018 IEEE International Symposium on* (2018), IEEE, pp. 1–4.
- [101] YU, Z.; XU, E.; DU, H.; GUO, B.; YAO, L. Inferring user profile attributes from multi-dimensional mobile phone sensory data. *IEEE Internet of Things Journal* (2019).
- [102] ZHANG, M.; SAWCHUK, A. A. A feature selection-based framework for human activity recognition using wearable multimodal sensors. In *Proceedings of the 6th International Conference on Body Area Networks* (2011), ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), pp. 92–98.
- [103] ZHENG, Y.; LI, Q.; CHEN, Y.; XIE, X.; MA, W.-Y. Understanding mobility based on gps data. In *Proceedings of the 10th international conference on Ubiquitous computing* (2008), ACM, pp. 312–321.
- [104] ZHENG, Y.; XIE, X.; MA, W.-Y., ET AL. Geolife: A collaborative social networking service among user, location and trajectory. *IEEE Data Eng. Bull.* 33, 2 (2010), 32–39.
- [105] ZHOU, X.; YU, W.; SULLIVAN, W. C. Making pervasive sensing possible: Effective travel mode sensing based on smartphones. *Computers, Environment and Urban Systems* 58 (2016), 52–59.
- [106] ZHU, C.; CHENG, Q.; SHENG, W. Human activity recognition via motion and vision data fusion. In *Signals, Systems and Computers (ASILOMAR), 2010 Conference Record of the Forty Fourth Asilomar Conference on* (2010), IEEE, pp. 332–336.