

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
DEPARTAMENTO DE INFORMÁTICA E ESTATÍSTICA**

Wagner Daufenbach do Amaral

**UM MODELO DE RECONHECIMENTO DE  
ATIVIDADES HUMANAS EM AMBIENTES  
DOMICILIARES ASSISTIDOS**

Florianópolis

2017



Wagner Daufenbach do Amaral

**UM MODELO DE RECONHECIMENTO DE  
ATIVIDADES HUMANAS EM AMBIENTES  
DOMICILIARES ASSISTIDOS**

Trabalho de conclusão de curso submetido ao curso de Sistemas de Informação para a obtenção do Grau de Bacharel em Sistemas de Informação.  
Orientador: Prof. Dr. Mario Antônio Ribeiro Dantas

Florianópolis

2017



Wagner Daufenbach do Amaral

**UM MODELO DE RECONHECIMENTO DE  
ATIVIDADES HUMANAS EM AMBIENTES  
DOMICILIARES ASSISTIDOS**

Este Trabalho de conclusão de curso foi julgado aprovado para a obtenção do Título de “Bacharel em Sistemas de Informação”, e aprovado em sua forma final pelo curso de Sistemas de Informação.

Florianópolis, 30 de Outubro 2017.

---

Prof. Dr. Cristian Koliver  
Coordenador

**Banca Examinadora:**

---

Prof. Dr. Mario Antônio Ribeiro Dantas  
Orientador

---

Prof. Dr. Elder Rizzon Santos

---

Prof. Dr. José Leomar Todesco

---

Profa. Dra. Patrícia Della Méa Plentz



## AGRADECIMENTOS

Primeiramente gostaria de agradecer ao meu professor e orientador, Dr. Mario Dantas, que esteve sempre disponível quando precisei de auxílio. O conhecimento que me foi passado durante todos nossos encontros são de valor inestimável.

A toda equipe do SeTIC, em especial ao meu supervisor Alexandre Gava Menezes, pela compreensão e apoio durante toda essa jornada.

Gostaria de ressaltar e agradecer o apoio incondicional que recebi dos meus pais, Jair Batista do Amaral e Rita Daufenbach do Amaral, e da minha irmã, Thais Daufenbach do Amaral, que, de forma especial e da forma deles, sempre confiaram em mim.

A minha namorada, María Gabriela López Peralta, que esteve ao meu lado nos melhores e nos piores momentos, sempre me apoiando e me dando forças.

Agradeço também a todos meus amigos, que de uma forma ou outra, direta ou indiretamente, contribuíram para o resultado final deste trabalho. Seria injusto citar nomes, correndo o risco de esquecer pessoas que em muito contribuíram em minha formação.





“What we wish, we readily believe, and what we ourselves think, we imagine others think also.”

(**Julius Caesar**, 100 A.C. - 44 A.C.)



## RESUMO

Com o crescimento da população de idosos, torna-se necessária a criação de condições que garantam a eles uma vida com qualidade e independência. A partir deste cenário, surgem os ambientes domiciliares assistidos, onde sensores corporais e de ambiente monitoram a saúde destes indivíduos. Com a finalidade de compreender a rotina individual de indivíduos monitorados, para prever de forma mais precisa anomalias na saúde dos mesmos, este trabalho apresenta um modelo para inferir as atividades realizadas pelos indivíduos, a partir de dados de localização e movimentação, gerados a partir de um acelerômetro. Foram monitoradas as atividades de 5 indivíduos, de diferentes faixas etárias, utilizando as atividades de 4 destes indivíduos para treinar o modelo e as atividades do indivíduo restante para dados de teste. Para a predição das atividades foi utilizado o algoritmo Extra Trees, onde foram obtidos os resultados de 81,16% de precisão quando utilizados apenas dados de movimentação, 92,59% quando utilizados tanto dados de movimentação quanto localização, e 97,56% quando utilizados dados de movimentação e dados sintéticos de localização.

**Palavras-chave:** Ambientes domiciliares assistidos. AAL. Reconhecimento de Atividade Humana.



## ABSTRACT

With the rising of elderly population, it becomes necessary the creation of conditions that ensure a life with quality and independence for these people. From this scenario, emerges the Ambient Assisted Living, where ambient and wearable sensors monitor people. For the purpose of understand a monitored person's daily routine, to predict more precisely health anomalies, this work presents a human activity recognition model, using location and movement data, generated from an accelerometer. The activities of 5 individuals, from different age groups, were monitored, using the activities of 4 of these individuals to train the model and the activities of the remaining individual for test data. For the prediction of the activities, the algorithm Extra Trees was used, where the results of 81.16% accuracy were obtained when only movement data were used, 92.59% when using both movement and location data, and 97.56% when used movement data and synthetic location data.

**Keywords:** Ambient Assisted Living. AAL. Human Activity Recognition.



## LISTA DE FIGURAS

Figura 1	Exemplo de um sistema distribuído.....	24
Figura 2	Arquitetura da Cloud Computing.....	25
Figura 3	Fog entre Cloud Computing e borda.....	26
Figura 4	Árvore de Decisão.....	29
Figura 5	Empilhamento de módulos Tinyduino.....	32
Figura 6	Taxonomia das publicações de HAR que utilizam acelerômetro.....	37
Figura 7	Número de publicações por ano.....	37
Figura 8	Comparação por ano entre sensor único e múltiplos sensores.....	38
Figura 9	Comparação por ano entre sensores autônomos e smartphones.....	39
Figura 10	Métodos de classificação utilizados para o reconhecimento de atividades humanas.....	40
Figura 11	Visão geral do modelo HARA.....	41
Figura 12	Diagrama UML do modelo HARA.....	42
Figura 13	Tinyduino, shield BLE e shield de acelerômetro.....	43
Figura 14	Sistema de detecção de movimentação.....	44
Figura 15	Planta da Casa.....	48
Figura 16	Importância das Características - Cenário I.....	51
Figura 17	Matriz de Confusão - Cenário I.....	52
Figura 18	Importância das Características - Cenário II(a).....	53
Figura 19	Matriz de Confusão - Cenário II(a).....	54
Figura 20	Importância das Características - Cenário II(b).....	56
Figura 21	Matriz de Confusão - Cenário II(b).....	56





## LISTA DE TABELAS

Tabela 1	Primeira fase de coleta de dados para a revisão da literatura.....	34
Tabela 2	Segunda fase de coleta de dados para a revisão da literatura.....	34
Tabela 3	Análise e síntese de dados para a revisão da literatura .	35
Tabela 4	Comparativo de Trabalhos de Pesquisa .....	35
Tabela 5	Obras mais citadas dentre os documentos analisados...	36
Tabela 6	Especificações do Atmel ATmega328P .....	43
Tabela 7	Localização - Codificação Binária.....	45
Tabela 8	Roteiro de atividades.....	49
Tabela 9	Comparativo Validação Cruzada - Cenário I.....	50
Tabela 10	Comparativo Validação Cruzada - Cenário II(a) .....	53
Tabela 11	Comparativo Validação Cruzada - Cenário II(b) .....	55



## LISTA DE ABREVIATURAS E SIGLAS

AAI	<i>Ambient Assisted Living</i> - Ambientes Assistidos
BLE	<i>Bluetooth Low Energy</i>
DaaS	<i>Development as a Service</i> - Desenvolvimento como Serviço
HAR	<i>Human Activity Recognition</i> - Reconhecimento de Atividade Humana
IaaS	<i>Infrastructure as a Service</i> - Infraestrutura como Serviço
IoT	<i>Internet of Things</i> - Internet das Coisas
K-NN	k-nearest neighbors - k-vizinhos mais próximos
MEMS	<i>Micro-Electro-Mechanical Systems</i> - Sistemas Microeletromecânicos
PaaS	<i>Platform as a Service</i> - Plataforma como Serviço
RFID	<i>Radio-Frequency Identification</i> - Identificação por Rádio-frequência
SaaS	<i>Software as a Service</i> - Software como Serviço



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	21
1.1	OBJETIVOS GERAIS	22
1.2	OBJETIVOS ESPECÍFICOS	22
1.3	ORGANIZAÇÃO DO TEXTO	22
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	23
2.1	INTERNET OF THINGS	23
2.2	AMBIENTES DISTRIBUÍDOS	23
2.2.1	Cloud Computing	24
2.2.2	Fog Computing	25
2.3	APRENDIZAGEM DE MÁQUINA	26
2.3.1	Reconhecimento de Padrões	27
2.3.2	Ensemble methods	28
2.3.3	Árvore de Decisão	28
2.3.3.1	Extra Trees	29
2.4	SENSORES CORPORAIS E DE AMBIENTE	30
2.4.1	Acelerômetro	30
2.4.2	Tinyduino	31
2.4.3	Comunicação	32
2.4.3.1	Bluetooth Low Energy	32
<b>3</b>	<b>TRABALHOS CORRELATOS</b>	33
3.1	COLETA DOS DADOS	34
3.2	ANÁLISE E SÍNTESE DOS DADOS	34
3.2.1	Comparativo das Abordagens	35
3.2.2	Referências Mais Citadas	36
3.3	REPRESENTAÇÃO DOS DADOS	36
3.3.1	Taxonomia das publicações	36
3.3.2	Publicações por Ano	37
3.3.3	Comparação por ano entre sensor único e múltiplos sensores	38
3.3.4	Comparação por ano entre sensores autônomos e smartphones	38
3.3.5	Métodos de classificação	39
<b>4</b>	<b>PROPOSTA - HARA</b>	41
4.1	OBTENÇÃO DOS DADOS	42
4.1.1	Movimentação	43
4.1.2	Localização	44
4.2	RECONHECIMENTO DAS ATIVIDADES	45

4.2.1	Seleção de Características .....	45
<b>5</b>	<b>AMBIENTES E RESULTADOS .....</b>	<b>47</b>
5.1	ESPECIFICAÇÃO DO AMBIENTE .....	47
5.2	ROTEIRO DE ATIVIDADES .....	48
5.3	CENÁRIOS E RESULTADOS .....	49
<b>5.3.1</b>	<b>Cenário I - Dados de Movimentação .....</b>	<b>49</b>
5.3.1.1	Validação Cruzada .....	50
5.3.1.2	Importância das Características .....	50
5.3.1.3	Precisão do Modelo .....	51
<b>5.3.2</b>	<b>Cenário II(a) - Dados de Movimentação e Locali- zação .....</b>	<b>52</b>
5.3.2.1	Validação Cruzada .....	52
5.3.2.2	Importância das Características .....	53
5.3.2.3	Precisão do Modelo .....	54
<b>5.3.3</b>	<b>Cenário II(b) - Dados de Localização Sintéticos ...</b>	<b>54</b>
5.3.3.1	Validação Cruzada .....	55
5.3.3.2	Importância das Características .....	55
5.3.3.3	Precisão do Modelo .....	56
5.4	CONSIDERAÇÕES DO CAPÍTULO .....	57
<b>6</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS ....</b>	<b>59</b>
	<b>REFERÊNCIAS .....</b>	<b>61</b>
	<b>APÊNDICE A - Artigo Publicado .....</b>	<b>69</b>
	<b>APÊNDICE B - Código Fonte .....</b>	<b>79</b>
	<b>APÊNDICE C - Artigo do TCC .....</b>	<b>105</b>

## 1 INTRODUÇÃO

Segundo projeções do IBGE datadas de 2013, o número de idosos - pessoas com mais de 60 anos - no Brasil em 2016, representaria aproximadamente 12% da população total do país. Já para 2060, o instituto projeta que a população de idosos representará quase 34% da população do Brasil. Em números absolutos a estimativa é que o número de idosos praticamente triplique até 2060 (IBGE, 2013).

Com esse grande crescimento da população de idosos, vê-se a oportunidade e a necessidade da criação de condições que garantam a eles uma vida com qualidade e independência. Com base nisso estão surgindo tecnologias que monitoram indivíduos em suas casas, os chamados Ambientes Domiciliares Assistidos. Apesar dos sistemas de detecção de atividade humana reforçarem a noção de que o principal público-alvo diz respeito à população de idosos, é importante ressaltar que, de uma forma geral, esse tipo de sistema, assim como o modelo proposto, pode ser útil para quaisquer pessoas, independentemente de sua faixa etária ou outras características que as definem.

Um Ambiente Domiciliar Assistido é composto por um conjunto heterogêneo de sensores corporais e de ambiente que geram grandes volumes de dados. Estes ambientes usam diversas técnicas para detecção de anormalidades, porém, de uma forma geral, detectam anormalidades somente quando elas ocorrem, o que muitas vezes está ligado a um estado avançado de uma doença. Neste tipo de sistema, não é possível prever anomalias com tempo hábil para que ações preventivas seja tomadas, o que evitaria que a situação se torne crítica (FORKAN et al., 2015).

Ao armazenar dados do posicionamento na residência e movimentação de um indivíduo monitorado, podemos inferir suas atividades diárias e assim entender sua rotina individual, detectando de forma mais precisa, e com antecedência, possíveis anomalias em sua saúde.

A partir disso, este trabalho de pesquisa propõe um modelo de detecção de atividade humana, baseado em dados de movimentação e localização, a partir de dispositivos de baixo custo e pequenas dimensões, focado na não intrusividade, garantindo assim uma vida com mais liberdade e qualidade para o indivíduo monitorado.

O presente trabalho se trata de um estudo conduzido de maneira progressiva ao longo dos dois últimos anos. Resultados parciais da pesquisa são discutidos em (AMARAL; DANTAS, 2017), artigo apresentado no Workshop de Iniciação Científica do XVIII Simpósio em Sistemas

Computacionais de Alto Desempenho. Para otimizar a visualização e a compreensão do estudo como um todo, serão utilizados e explanados - em momento oportuno do presente trabalho - conceitos apresentados e procedimentos realizados e documentados no artigo em questão, bem como os resultados alcançados no mesmo.

## 1.1 OBJETIVOS GERAIS

Desenvolver uma pesquisa, e implementar uma abordagem que seja capaz de reconhecer as atividades realizadas por um indivíduo monitorado, em um Ambiente Domiciliar Assistido, a partir de dados de localização e movimentação.

## 1.2 OBJETIVOS ESPECÍFICOS

- Pesquisar trabalhos relacionados a ambientes domiciliares assistidos.
- Desenvolver uma abordagem de captação da movimentação de um indivíduo.
- Desenvolver uma abordagem de localização *indoor*.
- Inferir as atividades realizadas por um indivíduo através dos dados de localização e movimentação do mesmo.
- Especificar e implementar um protótipo que valide o modelo através de dados experimentais de teste.

## 1.3 ORGANIZAÇÃO DO TEXTO

Este trabalho está organizado da seguinte forma: no capítulo 2 é apresentada a fundamentação dos conceitos necessários para o desenvolvimento deste trabalho; no capítulo 3 é realizada uma análise dos trabalhos correlatos; no capítulo 4 é apresentada e detalhada a proposta; o ambiente e os resultados obtidos são apresentados no capítulo 5; conclui-se o trabalho e trabalhos futuros são propostos no capítulo 6.



## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, serão apresentados e discutidos os principais conceitos necessários para compreender e embasar a proposta apresentada no capítulo 4.

### 2.1 INTERNET OF THINGS

Kevin Ashton acredita ter criado o termo *Internet of Things* durante uma apresentação, no ano de 1999 (ASHTON, 2009). Apesar do termo possuir quase 20 anos, somente mais recentemente passou a ser amplamente difundido. O motivo deste intervalo de tempo pode ser explicado pela falta de integração entre os elementos existentes para compor a IoT, condição necessária para operabilidade da mesma. Elementos como código de barras, GPS e RFID operavam de forma independente (MOORE, 2009 apud WEBER; WEBER, 2010, p. 2).

Segundo Dohr et al. (2010), o termo IoT engloba os conceitos de Comunicação Ubíqua, Computação Pervasiva e Ambientes Inteligentes. Para os autores do artigo, Comunicação Ubíqua é a habilidade de objetos se comunicarem em qualquer lugar, a qualquer momento; Computação Pervasiva é a evolução dos objetos computacionais, quando todo ambiente ao nosso redor transforma-se em um sistema computacional; Ambiente Inteligente é a capacidade de objetos registrarem as mudanças em um ambiente e como consequência, ativamente interagir com este ambiente.

Para Haller, Karnouskos e Schroth (2009), o papel da *Internet of Things* é estabelecer uma relação entre o mundo físico e sua representação em sistemas de informação. Para que isso seja possível, objetos físicos devem participar de forma ativa na interação com serviços disponibilizados via internet, levando em consideração questões de segurança e privacidade.

### 2.2 AMBIENTES DISTRIBUÍDOS

Tanenbaum e Steen (2006), definem sistemas distribuídos como uma coleção de computadores que aparecem para seus usuários como sendo um único sistema. Uma das características desta coleção de computadores é a independência de cada computador. Mesmo quando uma

parte do sistema está com problemas ou indisponível, devido a independência, o sistema deve continuar funcionando como um todo. A troca, adição ou manutenção de partes no sistema não deve ser percebida pelos usuários.

Para Babaoglu e Marzullo (1993), um sistema distribuído pode ser entendido como uma coleção de processos sequenciais e uma rede capaz de implementar um canal de comunicação unidirecional entre pares de processos, para troca de mensagem. Na computação distribuída, a atividade de cada processo sequencial é modelada como a execução de uma sequência de eventos. Um evento pode ser tanto interno ao processo e causar apenas uma mudança de estado local, quanto envolver comunicação com outro processo. A Figura 1 representa os processos e os canais de comunicações de um sistema distribuído.




Figura 1: Exemplo de um sistema distribuído

Fonte: (CHANDY; LAMPORT, 1985).

### 2.2.1 Cloud Computing

Segundo Buyya et al. (2009), *Cloud Computing* é um tipo de sistema paralelo e distribuído, que consiste em uma coleção de computadores interconectados e virtualizados, que são dinamicamente apresentados como recursos computacionais unificados. Os recursos personalizados oferecidos são baseados no acordo de nível de serviço, e este é estabelecido através da negociação entre o provedor do serviço e o consumidor.

A arquitetura da *Cloud Computing* pode ser definida em uma

pirâmide composta por 4 elementos: *Infrastructure as a service* (IaaS), *Platform as a service* (PaaS), *Data as a Service* (DaaS) e *Software as a service* (SaaS) (HASSAN, 2011). Como pode ser observado na Figura 2, na base da pirâmide fica a IaaS, que oferece recursos de hardware, o que garante uma maior liberdade e controle para o cliente. No centro se localizam a PaaS e o DaaS. A PaaS oferece uma plataforma para acessar recursos de hardware, apresentando menor flexibilidade que a IaaS. Já o DaaS, oferece serviço de armazenamento de dados. No topo da pirâmide temos o SaaS, que oferece aplicações de software, abstraindo toda a parte de configuração e gerenciamento de hardware.

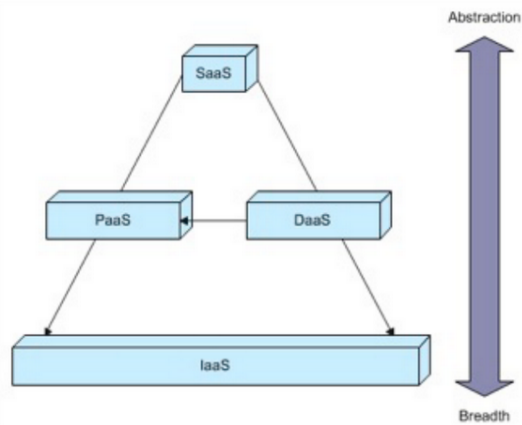


Figura 2: Arquitetura da Cloud Computing

Fonte: (HASSAN, 2011).

### 2.2.2 Fog Computing

A origem do termo *Fog Computing*, ou simplesmente *Fog*, é recente, data de 2011. O termo foi cunhado pela Cisco, e representa uma expansão do paradigma da *Cloud Computing* para a borda da rede. As características que definem a *Fog* são (BONOMI et al., 2012):

- Baixa latência e senso de localização;
- Ampla distribuição geográfica;
- Mobilidade;

- Elevado número de nós;
- Predomínio do acesso sem fio;
- Forte presença de aplicações em tempo real;
- Estrutura heterogênea.

Para Stojmenovic e Wen (2014), na *Fog Computing*, os serviços podem ser hospedados em dispositivos finais. A infraestrutura desta nova computação distribuída permite que as aplicações funcionem o mais próximo possível dos dados sensíveis, provenientes de pessoas, processos ou objetos. De forma sintética, os autores do artigo citam que a *Fog* pode ser entendida como uma *Cloud Computing* próxima ao "chão".




Figura 3: Fog entre Cloud Computing e borda

Fonte: (STOJMENOVIC; WEN, 2014).

### 2.3 APRENDIZAGEM DE MÁQUINA

O termo aprendizagem de máquina refere-se à detecção automatizada de padrões significativos em dados. A técnica permite a extração de informação de grandes conjuntos de dados. Alguns exemplos de aplicações de aprendizagem de máquina são: sistemas de recomendações de produtos, filtragem de e-mails e detecção de fraude em transações com

cartões de crédito, além de ser amplamente utilizado em aplicações científicas como bioinformática, medicina e astronomia (SHALEV-SHWARTZ; BEN-DAVID, 2014).

Ainda segundo Shalev-Shwartz e Ben-David (2014), uma característica comum a todas as aplicações que utilizam aprendizagem de máquina diz respeito a complexidade dos padrões a qual a aplicação terá de reconhecer, não sendo possível a um programador humano fornecer uma especificação explícita e detalhada de como as tarefas desta aplicação devem ser executadas.

Para Mohri, Rostamizadeh e Talwalkar (2012), a aprendizagem de máquina pode ser definida, de forma genérica, como métodos computacionais que usam informações prévias disponíveis para melhorar seu desempenho ou para fazer previsões mais precisas. A qualidade e o tamanho destas informações disponíveis são cruciais para o sucesso das previsões realizadas, assim, a aprendizagem de máquina é inerentemente relacionada a área de análise de dados e a estatística.

### **2.3.1 Reconhecimento de Padrões**

O reconhecimento de padrões cobre uma grande variedade de problemas, resultando em uma dificuldade de se estabelecer uma visão ou abordagem unificada. O principal objetivo na área é entender o complexo mecanismo de tomada de decisão e automatizar este processo utilizando computadores. Porém, devido a complexidade deste mecanismo, a maioria das pesquisas na área focam em problemas mais realistas, como reconhecimento de caracteres ou a classificação das formas de onda (FUKUNAGA, 2013).

No reconhecimento de padrões a classificação de um grupo de objetos é baseada em certos requisitos subjetivos. Os objetos que são classificados em uma mesma categoria, normalmente compartilham algumas propriedades. Os requisitos de classificação são subjetivos, uma vez que diferentes classificações ocorrem sob diferentes situações (FU, 1968).

Para Bishop (2006), reconhecimento de padrões e aprendizagem de máquina podem ser vistos como duas facetas da mesma área de estudo, apesar de possuírem origens distintas. O primeiro termo é originado da engenharia, enquanto o segundo surgiu da ciência da computação.

Ainda segundo Bishop (2006), o reconhecimento de padrões está envolvido com a descoberta automatizada de simetria em dados através

do uso de algoritmos computacionais, e com o uso destas simetrias para a tomada de ação, como a classificação dos dados em diferentes categorias. Um conceito chave na área é o da incerteza, que surge tanto de ruídos em medições, quanto através do tamanho finito dos conjuntos de dados. Para lidar com o problema da incerteza, faz-se o uso da teoria da probabilidade.

### 2.3.2 Ensemble methods

*Ensemble Methods* são algoritmos de aprendizagem que constroem um conjunto de classificadores e, em seguida, classificam novos dados a partir de um voto ponderado dos seus classificadores. Geralmente a estimativa dos *Ensemble Methods* é muito mais precisa do que as estimativas individuais dos classificadores que os compõem (DIETERICH, 2000).

Scikit-Learn (2017), divide os *Ensemble methods* em duas famílias distintas:

- **Averaging Methods** - são construídos vários estimadores independentes e, em seguida, faz-se uma média de suas previsões.
- **Boosting Methods** - são construídos estimadores de base única de forma sequencial para tentar reduzir o viés do estimador combinado. A motivação é combinar vários modelos fracos para produzir um conjunto poderoso.

### 2.3.3 Árvore de Decisão

Segundo Yu et al. (2010), Árvore de Decisão é um método de classificação que usa um esquema de árvore semelhante a um fluxograma para dividir dados em classes pré-definidas. Assim é possível prever o valor de uma variável de destino usando os valores de um conjunto de variáveis preditoras. A Figura 4(a) apresenta um exemplo de um conjunto de dados de treino, e a Figura 4(b) mostra a Árvore de Decisão resultante.

Este método de classificação utiliza o conceito de aprendizado supervisionado. Aprendizado supervisionado é uma categoria da aprendizagem de máquina onde o sistema responsável pela predição recebe como dados de treinamento um conjunto de exemplos já classificados (MOHRI; ROSTAMIZADEH; TALWALKAR, 2012).




Figura 4: Árvore de Decisão

Fonte: (RASTOGI; SHIM, 2000).

Safavian e Landgrebe (1991), especificam que a criação de uma Árvore de Decisão passa por 4 objetivos básicos:

1. Classificar corretamente o maior número possível dos dados de treino;
2. Generalizar a classificação para além dos dados de treino, sendo capaz de classificar com alta precisão um conjunto novo de dados;
3. Ser de fácil atualização, uma vez que novos dados de treino podem surgir;
4. Possuir a estrutura o mais simples possível.

### 2.3.3.1 Extra Trees

O método de classificação *Extra Trees*, nome que provém de *Extremely Randomized Trees*, foi proposto por Geurts, Ernst e Wehenkel (2006), utilizando o conceito de *Ensemble Method* e sendo caracterizado por divisões randômicas ou parcialmente randômicas, tanto dos atributos quanto dos pontos de corte.

O artigo ressalta ainda que as duas principais diferenças em relação a outros *Ensemble Methods* baseados em Árvore de Decisão, diz respeito às divisões randômicas e ao uso de todo o conjunto de dados de treino, ao invés de subgrupos, para a criação das árvores.

Com relação ao equilíbrio entre viés e variância, Árvores de Decisão são caracterizadas por baixo viés e alta variância. A partir das randomizações, o método *Extra Trees* aumenta um pouco o viés, porém consegue reduzir significativamente a variância.

## 2.4 SENSORES CORPORAIS E DE AMBIENTE

Tipicamente, um sensor converte um parâmetro físico a ser medido em sinais elétricos, que são em seguida analisados e interpretados. Um sensor pode responder a diversos tipos de estímulos físicos, como velocidade, pressão e temperatura. Idealmente, um sensor monitora o estado de um sistema sem afetá-lo (HAK, 2001).

Avanços na tecnologia de Sistemas Microeletromecânicos (MEMS), comunicação sem fio e eletrônica digital, possibilitaram o desenvolvimento de sensores multifuncionais de baixo custo e baixo consumo energético, que são pequenos em tamanho e comunicam-se livremente em curtas distância (AKYILDIZ et al., 2002).

Sensores corporais são sensores portáteis que podem ser anexados a pessoas. Estes sensores são atualmente os mais adequados para monitoramento de mobilidade, atividades físicas e progresso em uma reabilitação (KANG et al., 2010).

Já os sensores de ambiente são responsáveis por monitorar e coletar informações do ambiente no qual se encontram. Essas informações podem identificar possíveis atividades ou situações perigosas ou garantir, aos cuidadores à distância, que um medicamento foi tomado, ou uma refeição consumida. Sensores de ambiente apresentam algumas vantagens quando comparados a sensores corporais, eles são caracterizados por não serem intrusivos e evitam problemas como o mal posicionamento ou a danificação do sensor, comuns nos sensores corporais (KANG et al., 2010).

A combinação de sensores corporais e de ambiente traz benefícios para a área de monitoramento de pacientes. Informações coletadas usando sensores corporais têm sua significância aumentada quando combinadas com informações coletadas por sensores de ambiente (PATEL et al., 2012).

### 2.4.1 Acelerômetro

Um acelerômetro é um sensor eletromecânico que mede as forças de aceleração. Essas forças podem ser estáticas, ou dinâmicas. Ao medir a quantidade de aceleração estática devido à gravidade, é possível determinar qual o ângulo de inclinação do sensor em relação a terra. Ao medir a quantidade de aceleração dinâmica, é possível analisar de que forma o sensor está se movendo (GOODWIN; ISLAND, 2008).

Segundo Mathie et al. (2004), acelerômetros são instrumentos



que medem a aceleração aplicada sobre um eixo sensível. Existe uma grande variedade de tipos de acelerômetros, cada tipo pode usar diferentes mecanismos para medir a aceleração, além de serem projetados e produzidos utilizando diferentes técnicas de manufatura. Porém, conceitualmente, todos acelerômetros usam uma variação do sistema massa-mola. Neste sistema, quando a aceleração é aplicada, uma pequena massa dentro do acelerômetro responde aplicando uma força em uma mola, fazendo com que ela se estique ou comprima. O deslocamento da mola pode ser medido e usado para calcular a aceleração aplicada.

Acelerômetros oferecem algumas características que os torna ideais para o monitoramento de atividades humanas como (MATHIE et al., 2004):

- Respondem tanto a frequência quanto a intensidade de um movimento;
- Podem medir inclinação, assim como o movimento do corpo;
- Possuem pequenas dimensões e baixo custo.

## 2.4.2 Tinyduino

*TinyDuino* é uma plataforma eletrônica *open-source* em miniatura, baseado na plataforma *Arduino*. A plataforma é composta por uma placa processadora e múltiplos *TinyShields*, que adicionam funções específicas a plataforma, como sensores, comunicação e opções de exibição. Cada módulo na família *TinyDuino* inclui somente os circuitos essenciais, e possuem o tamanho aproximado de uma moeda americana de 25 centavos. Os módulos podem ser unidos por meio de empilhamento, como pode ser observado na Figura 5 (TINYCIRCUITS, 2017).




Figura 5: Empilhamento de módulos Tinyduino

Fonte: (TINYCIRCUITS, 2017).

### 2.4.3 Comunicação

As redes sem fio de sensores possuem como aspecto chave o consumo de energia, já que normalmente os sensores são alimentados por bateria. A parte do sensor responsável pela comunicação é geralmente o componente que consome mais energia. Não somente transmitir dados consome energia, as atividades relacionadas a comunicação, como receber dados ou o monitoramento do ambiente para detectar comunicações, podem consumir até metade da bateria de um sensor (DAM; LANGENDOEN, 2003; STEMM; KATZ, 1997).

#### 2.4.3.1 Bluetooth Low Energy

*Bluetooth Low Energy* (BLE), é uma tecnologia *wireless*, desenvolvida pelo *Bluetooth Special Interest Group*, para comunicação de pequenas distâncias. Diferente das especificações dos *Bluetooth* anteriores, o BLE foi projetado para ser uma solução de baixíssimo consumo energético para aplicações de controle e monitoramento (GOMEZ; OLLER; PARADELLS, 2012).

Um dispositivo BLE pode operar tanto no modo mestre quanto no modo escravo. No modo mestre o BLE pode gerenciar múltiplas conexões simultâneas com diversos dispositivos no modo escravo, mas o BLE no modo escravo pode somente ser conectado a um único dispositivo no modo mestre. Desta forma, o BLE possui uma topologia de rede em estrela (SIEKKINEN et al., 2012).

### 3 TRABALHOS CORRELATOS

Nos últimos anos, muitos artigos passaram a abordar o tema de ambientes assistidos. Por se tratar de um conceito relativamente novo, poucos padrões são encontrados na literatura. Alguns trabalhos, como (LEE; KHAN; KIM, 2011), (MANNINI et al., 2013), utilizam apenas um único acelerômetro para o reconhecimento das atividades. Outros trabalhos, como (DWIYANTORO; NUGRAHA; CHOI, 2016), (MURAO; TERADA, 2016) e (KIM; KANG; KIM, 2015), utilizam diversos sensores para a mesma finalidade.

O uso de sensores corporais é amplamente utilizado nessa área, porém outras abordagens também são encontradas na literatura, como a utilização de imagens para o reconhecimento das atividades. Esse é o caso de trabalhos como (MAURER et al., 2006).

Para os sensores corporais, a posição do corpo onde o dispositivo será acoplado possui grande importância. Apesar de também não existir um padrão sobre onde os sensores devem ser posicionados, alguns dos lugares mais comuns são: peito, pulso, tornozelo e cintura. Em (ATALLAH et al., 2011) é realizado um estudo para determinar o melhor posicionamento para sensores corporais.

Em Noor, Salcic e Wang (2017), a identificação de atividades humanas é feita através de um único acelerômetro triaxial, utilizando o conceito de janelas de tamanho dinâmico. O sistema de classificação consiste de três classificadores, sendo cada um deles implementado como uma árvore de decisão. Nesse trabalho, que utiliza apenas dados de movimentação, foi atingida uma precisão média de 95,4%.

Já em Chevalier (2016), é proposto um modelo que utiliza uma *Recurrent Neural Networks* para o sistema de classificação. Para essa classificação, o modelo utiliza um conjunto público de dados de atividades humanas, disponível em (ANGUITA et al., 2013). Diferentemente do modelo citado anteriormente, esse modelo utiliza dados provenientes de um smartphone, e são utilizados as informações do acelerômetro e do giroscópio deste dispositivo. A precisão média do sistema ficou em 91,55%.

Para melhor compreender o estado atual da pesquisa nessa área, realizou-se uma revisão da literatura. O processo foi dividido em 3 etapas: coleta de dados, análise e síntese dos dados e representação dos dados.

### 3.1 COLETA DOS DADOS

Na primeira fase da etapa de coleta dos dados, foram realizadas buscas pelo termo “*activity recognition*” no título de documentos de 4 bases de dados: *IEEE Xplorer*, *ProQuest*, *Scopus* e *Web of Science*.

Esta primeira fase de coleta de dados foi realizada em janeiro de 2017, e o resultado desta coleta pode ser visualizado na tabela 1.

Devido ao extenso volume de documentos, que ultrapassa o número de 5500 na soma de todas as bases de dados, decidiu-se aplicar um novo filtro para o termo de busca. Nesta segunda fase de coleta de dados além da necessidade do título possuir o termo de busca inicial, ele também deve conter a palavra “*accelerometer*”.

Tabela 1: Primeira fase de coleta de dados para a revisão da literatura

Base de dados	Número de documentos encontrados
<i>IEEE Xplorer</i>	870
<i>ProQuest</i>	1389
<i>Scopus</i>	2044
<i>Web of Science</i>	1288
<b>Total</b>	<b>5591</b>

Esta segunda fase de coleta de dados também foi realizada em janeiro de 2017, assim como a primeira fase, e o resultado desta coleta pode ser visualizado na tabela 2.

Tabela 2: Segunda fase de coleta de dados para a revisão da literatura

Base de dados	Número de documentos encontrados
<i>IEEE Xplorer</i>	47
<i>ProQuest</i>	23
<i>Scopus</i>	108
<i>Web of Science</i>	75
<b>Total</b>	<b>253</b>

### 3.2 ANÁLISE E SÍNTESE DOS DADOS

Após a coleta dos dados, a etapa de análise e síntese dos dados compreende uma leitura rápida dos títulos e resumos dos documentos

encontrados. Foram avaliados apenas documentos que possuam texto completo disponível, e são excluídos documentos repetidos ou que sejam escritos em idioma diferente do inglês, português ou espanhol. O número de documentos selecionados para uma avaliação mais atenta, pode ser visualizado na tabela 3.

Tabela 3: Análise e síntese de dados para a revisão da literatura

Base de dados	Número de documentos selecionados
<i>IEEE Xplorer</i>	38
<i>ProQuest</i>	7
<i>Scopus</i>	27
<i>Web of Science</i>	4
<b>Total</b>	<b>76</b>

### 3.2.1 Comparativo das Abordagens

A Tabela 4 apresenta uma comparação entre as abordagens utilizadas em alguns dos trabalhos selecionados durante a revisão da literatura.

Tabela 4: Comparativo de Trabalhos de Pesquisa

Referência	Sensor	Localização do sensor	Método de classificação
(LEE; KHAN; KIM, 2011)	Acelerômetro	Peito	Artificial Neural Network
(MANNINI et al., 2013)	Acelerômetro	Pulso ou Tornozelo	Support Vector Machine
(DWIYANTORO; NUGRAHA; CHOI, 2016)	Acelerômetro e Sensor de gravidade (smartphone)	Bolso frontal da calça	Dynamic Time Warping e K-Nearest Neighbors
(MURAO; TERADA, 2016)	Múltiplos acelerômetros	Ambos pulsos e tornozelos e quadril	Dynamic Time Warping e Support Vector Machine
(KIM; KANG; KIM, 2015)	Acelerômetro e Giroscópio (smartphone)	Cintura	Hidden Markov Model

### 3.2.2 Referências Mais Citadas

Com a finalidade de identificar as obras mais citadas, foram verificadas todas as referências bibliográficas dos 76 documentos selecionados. Na tabela 5 são listadas as obras que foram referenciadas pelo menos 10 vezes dentre os documentos analisados.

Tabela 5: Obras mais citadas dentre os documentos analisados

Referência	Citações
Activity recognition from user-annotated acceleration data (BAO; INTILLE, 2004)	43
Activity recognition from accelerometer data (RAVI et al., 2005)	31
Activity recognition using cell phone accelerometers (KWAPISZ; WEISS; MOORE, 2011)	22
Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring (KARANTONIS et al., 2006)	16
A Triaxial Accelerometer-Based Physical-Activity Recognition via Augmented-Signal Features and a Hierarchical Recognizer (KHAN et al., 2010)	14
Activity recognition and monitoring using multiple sensors on different body positions (MAURER et al., 2006)	12
Recognizing human motion with multiple acceleration sensors (MANTYJARVI; HIMBERG; SEPPANEN, 2001)	11

## 3.3 REPRESENTAÇÃO DOS DADOS

### 3.3.1 Taxonomia das publicações

A imagem 6 apresenta a taxonomia dos 76 trabalhos selecionados. A busca e a seleção dos documentos baseou-se em trabalhos que tratam especificamente de identificação de atividade humana com o uso de acelerômetros. Trabalhos que utilizam diversos modelos, tanto com um único sensor, quanto com múltiplos sensores, foram classificados de acordo com o modelo considerado como o melhor pelos autores do trabalho.

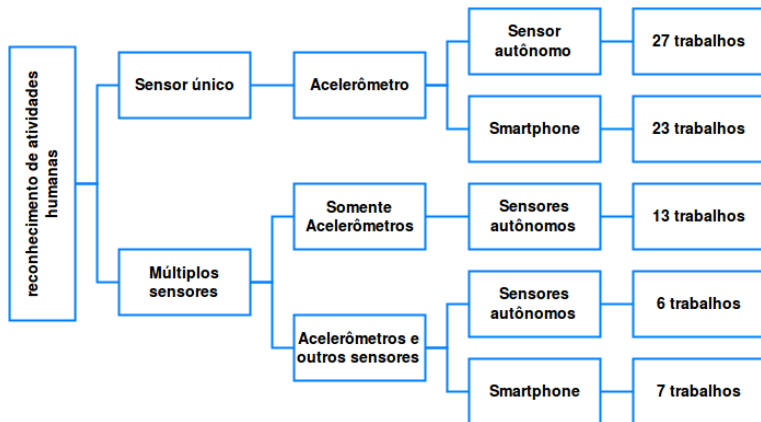


Figura 6: Taxonomia das publicações de HAR que utilizam acelerômetro

Fonte: elaborado pelo autor.

### 3.3.2 Publicações por Ano

A Figura 7 mostra a distribuição das publicações selecionadas ao longo dos anos. É possível observar uma tendência crescente no número de publicação, comprovando o grande interesse na área nos últimos anos.




Figura 7: Número de publicações por ano

Fonte: elaborado pelo autor.

### 3.3.3 Comparação por ano entre sensor único e múltiplos sensores

Quando comparamos trabalhos que usam um único sensor para o reconhecimento de atividades humanas, com trabalhos que utilizam múltiplos sensores para esta mesma função, percebemos que ambos possuem uma tendência crescente ao longo dos anos. Porém, ainda que ambos tendam a crescer, a taxa de crescimento de trabalhos que utilizam um único sensor é superior a de trabalhos que utilizam múltiplos sensores. Esta comparação é evidenciada na Figura 8.




Figura 8: Comparação por ano entre sensor único e múltiplos sensores

Fonte: elaborado pelo autor.

### 3.3.4 Comparação por ano entre sensores autônomos e smartphones

A Figura 9 apresenta a comparação entre trabalhos que utilizam sensores autônomos com trabalhos que utilizam smartphones para a identificação de atividades humanas. Nota-se que até 2009, nenhum dos trabalhos selecionados havia utilizado smartphones como um sistema de sensores, porém a partir de 2009, houve um rápido crescimento no número de trabalhos que utilizam estes dispositivos. A partir de 2012, o número de trabalhos que utilizam smartphones é muito semelhante ao número de trabalhos que utilizam sensores autônomos. Este rápido crescimento pode estar alinhado a popularização desses dispositivos.

Um dos pontos positivos mais considerados quando da utilização de smartphones, é a questão de sistemas intrusivos. Como grande



parte dos usuários monitorados já possuem um smartphone, não haverá nenhuma interferência extra, pois não será necessário a instalação de nenhum dispositivo novo no indivíduo monitorado.

Por outro lado trabalhos que não utilizam smartphones, citam a baixa autonomia destes dispositivos como um problema. O fato de smartphones necessitarem de recargas com uma frequência muito maior do que alguns sensores autônomos, contribui para que muitos trabalhos sigam utilizando sensores autônomos.




Figura 9: Comparação por ano entre sensores autônomos e smartphones

Fonte: elaborado pelo autor.

### 3.3.5 Métodos de classificação

A partir da leitura dos trabalhos selecionados, foram identificados os métodos de classificação utilizados para o reconhecimento de atividades humanas. Grande parte dos trabalhos utiliza mais de uma técnica de classificação, para posterior comparação entre técnicas. A Figura 10 representa a distribuição dessas técnicas de classificação entre os trabalhos selecionados.




Figura 10: Métodos de classificação utilizados para o reconhecimento de atividades humanas

Fonte: elaborado pelo autor.

## 4 PROPOSTA - HARA

Com o crescimento da expectativa de vida, soluções focadas para Ambientes Domiciliares Assistidos surgem com o objetivo de melhorar a qualidade de vida e garantir independência para idosos.

Este trabalho propõe um modelo de reconhecimento de atividade humana por indivíduos monitorados dentro de suas casas. Os dados a serem analisados para esta predição são de posicionamento e de movimentação.

A Figura 11 mostra uma visão geral, enquanto a figura 12 apresenta o diagrama de atividades do modelo proposto. As figuras representam desde a entrada de dados, que são capturados a partir de sensores, até a predição da atividade realizada pelo indivíduo monitorado.

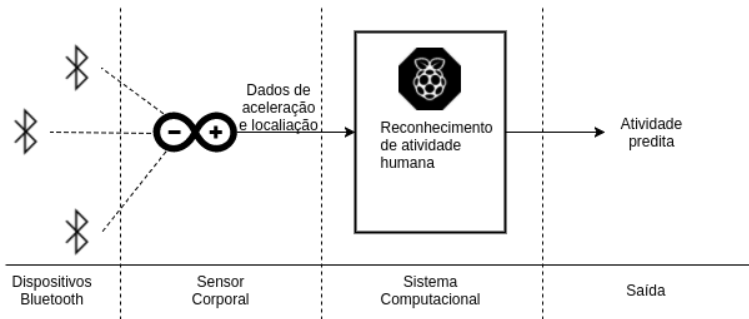


Figura 11: Visão geral do modelo HARA

Fonte: elaborado pelo autor.

O principal objetivo deste trabalho é propor um modelo capaz de inferir com precisão qual atividade o indivíduo monitorado está realizando a partir dos dados de localização e movimentação deste indivíduo.

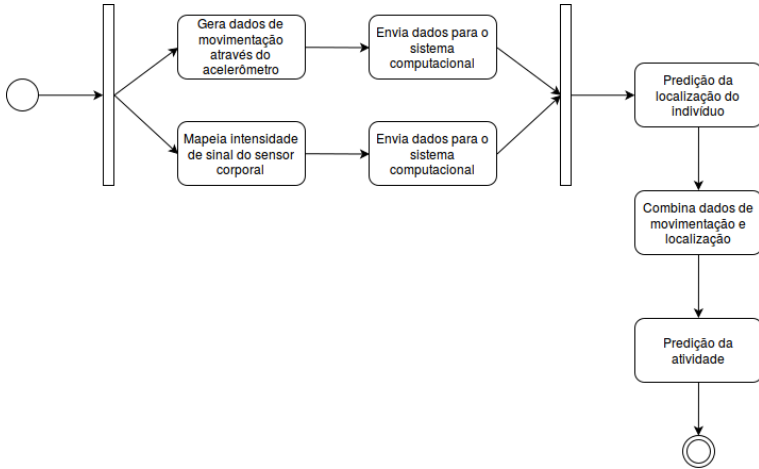


Figura 12: Diagrama UML do modelo HARA

Fonte: elaborado pelo autor.

#### 4.1 OBTENÇÃO DOS DADOS

Existem diversas propostas para a detecção de atividades humanas básicas. Normalmente elas são baseadas no reconhecimento de padrões de imagens, como em (MOESLUND; HILTON; KRÜGER, 2006) ou no uso, por parte do indivíduo, de diversos sensores corporais acoplados ao corpo, como em (MAURER et al., 2006). No caso do reconhecimento de padrões de imagens, existe um alto custo de processamento de imagens, enquanto o uso de diversos sensores corporais apresenta o inconveniente de ser muito invasivo e incômodo para o indivíduo (ZHU; SHENG, 2011).

Sabendo que as atividades de um indivíduo estão fortemente ligadas a sua localização dentro de casa (ZHU; SHENG, 2011), este trabalho apresenta uma solução alternativa aos dois métodos citados anteriormente. A movimentação do indivíduo é identificada a partir de um único acelerômetro acoplado ao corpo do indivíduo monitorado. Segundo Atallah et al. (2011) os melhores resultados para identificação de atividades domésticas foram encontrados quando o sensor corporal foi acoplado a cintura ou ao pulso do indivíduo monitorado. Visando a menor intrusividade possível, optou-se por utilizar o sensor no pulso do indivíduo nesta pesquisa. Para os dados de localização do indivíduo

dentro do ambiente dispositivos *Bluetooth* estarão espalhados pelo ambiente para mapear a intensidade do sinal enviado pelo sensor corporal.

#### 4.1.1 Movimentação

Para obter a movimentação do indivíduo, o mesmo carregará consigo um sensor corporal que será composto por um *Tinyduino*, um *shield* BLE para a comunicação entre o sensor e o sistema computacional, e um *shield* de acelerômetro. A placa de processamento é composta por uma microcontrolador Atmel ATmega328P, as especificações do microcontrolador podem ser vistas na Tabela 6. A placa principal e os *shields* podem ser vistos nas Figuras 13 e 14. As dimensões do sensor são 20mm x 20mm x 16.8mm.

Tabela 6: Especificações do Atmel ATmega328P

Parâmetro	Valor
Memória Flash	32 KB
Memória RAM	2 KB
EEPROM	1 KB
Clock speed (default)	8 Mhz



Figura 13: Tinyduino, shield BLE e shield de acelerômetro

Fonte: foto tirada pelo autor.



Figura 14: Sistema de detecção de movimentação

Fonte: foto tirada pelo autor.

### 4.1.2 Localização

Para a identificação da localização de um indivíduo, dispositivos *Bluetooth* estarão espalhados pelo ambiente. Estes dispositivos ficarão responsáveis por verificar a intensidade de sinal do *shield* BLE carregado pelo indivíduo no sensor corporal. A localização *indoor* do indivíduo monitorado será definida de acordo com a intensidade do sinal medido pelos dispositivos *Bluetooth*.

Nesta etapa será necessário treinar o modelo para reconhecer os ambientes da casa, andando com o sensor corporal pela casa e informando manualmente em qual ambiente o indivíduo se encontra.

O processo de identificação das localizações é descrito abaixo:

1. Cada um dos dispositivos *Bluetooth* persistirá os dados referente a intensidade do sinal do sensor corporal em um banco de dados MySQL a cada segundo;
2. O sistema computacional será responsável por ler os últimos 12 dados persistidos (teoricamente 3 de cada um dos dispositivos *Bluetooth*), e calcular a intensidade média de cada um dos dispositivos;
3. A intensidade média de cada um dos dispositivos é utilizada como característica para a predição da localização;
4. Será utilizado o algoritmo K-NN para predição da localização;
5. A predição será persistida no banco de dados.

## 4.2 RECONHECIMENTO DAS ATIVIDADES

Para o reconhecimento das atividades, foi selecionado o algoritmo *Extra Trees* implementado pela Scikit-learn (PEDREGOSA et al., 2011). Serão utilizados 80% dos dados disponíveis para treino e 20% para teste. Para avaliar o modelo, será realizado uma validação cruzada (*k-fold*) nos dados de treino, com 10 subconjuntos.

Para os dados do acelerômetro, é definido uma janela de 5 segundos, com sobreposição de 3 segundo, com exceção da última janela, que se adequará ao tempo disponível. Por exemplo, se tivermos dados referentes a 10 segundos de monitoramento do acelerômetro, teremos as seguintes janelas: [0s-5s], [2s-7s], [4s-9s], [5s-10s].

Devido ao algoritmo utilizado trabalhar apenas com dados numéricos, é necessário converter as localizações para este tipo de dado. A codificação binária foi escolhida para esta conversão, como temos 7 ambientes na casa, precisamos de 3 novas características. A conversão pode ser observada na tabela 7:

Tabela 7: Localização - Codificação Binária

Ambiente	Lugar_x0	Lugar_x1	Lugar_x2
Sala	0	0	0
Quarto	0	0	1
Cozinha	0	1	0
Corredor	0	1	1
Banheiro	1	0	0
Escritório	1	0	1
Área de Serviço	1	1	0

### 4.2.1 Seleção de Características

A seleção das características para a uso no algoritmo de reconhecimento de atividades baseou-se na proposta de Chevalier (2016). Cada uma das características é calculada levando-se em consideração os dados referente a sinais de 5 segundos de duração do acelerômetro, com exceção das características de localização. A seguir são listadas as características selecionadas:

- **Média**  $[X, Y, Z]$  - média dos valores de cada eixo;
- **Desvio Padrão**  $[X, Y, Z]$  - desvio padrão dos valores de cada

eixo;

- **Mediana [X, Y, Z]** - mediana dos valores de cada eixo;
- **Valor Máximo [X, Y, Z]** - maior valor de cada eixo;
- **Valor Mínimo [X, Y, Z]** - menor valor de cada eixo;
- **Energia [X, Y, Z]** - dada pela fórmula  $\frac{\sum_{i=1}^n (k_i^2)}{n}$  para os valores de cada eixo, onde n é a quantidade de valores;
- **Amplitude Interquartil [X, Y, Z]** - definida pela diferença entre o terceiro e o primeiro quartil dos valores de cada eixo;
- **Entropia [X, Y, Z]** - dado pela fórmula  $-\sum_{i=1}^n (k_i * \log(k_i))$  para os valores de cada eixo, onde n é a quantidade de valores.
- **Signal magnitude area (X, Y, Z)** - dado pela fórmula  $\frac{\sum_{i=1}^n (|x_i| + |y_i| + |z_i|)}{n}$ , onde n é a quantidade de valores em um eixo;
- **Correlação [(X,Y), (X,Z), (Y,Z)]** - coeficiente de correlação entre os dados dos eixos, dois a dois;
- **Lugar [x0, x1, x2]** - codificação binária referente a localização *indoor*.



## 5 AMBIENTES E RESULTADOS

Neste capítulo, serão apresentados os resultados experimentais do modelo proposto. Para esta etapa, foram monitorados 5 indivíduos, 2 destes com idades entre 20 e 30 anos, 1 com idade entre 30 e 40 anos e 2 com mais de 60 anos. Os dados de um dos indivíduos da faixa entre 20 e 30 anos foram utilizados como dados de teste e os dados dos demais indivíduos foram utilizados como dados de treino. Com os dados desse monitoramento foram criados dois cenários distintos. Primeiro foram utilizados apenas os dados de movimentação para o reconhecimento das atividades, em seguida além dos dados de movimentação também são utilizados os dados de localização *indoor*.

### 5.1 ESPECIFICAÇÃO DO AMBIENTE

O ambiente no qual os experimentos foram conduzidos pode ser observado na Figura 15. O sistema computacional (*Raspberry Pi 3 Model B*) foi posicionado na Cozinha, enquanto os dispositivos *Bluetooth* (três notebooks), foram posicionados no Escritório, Quarto e Sala.




Figura 15: Planta da Casa

Fonte: elaborado pelo autor.

## 5.2 ROTEIRO DE ATIVIDADES

A fim de gerar dados de uma grande variedade de atividades e localidades, aproximando-se da rotina real de um indivíduo, foi criado um roteiro de atividades. Atividades como andar e varrer, por exemplo, podem ser executadas em qualquer ambiente da casa, enquanto escovar os dentes é uma atividade exclusiva do banheiro.

Para cada classe de atividade definiu-se o tempo de 2 minutos, e este tempo foi dividido de forma igualitária entre as atividades desta classe. As classes que possuem menos atividades, dispõem de mais tempo para cada atividade, como é o caso da classe Alta Intensidade, que por possuir apenas uma atividade, dispõe de 120 segundos para a atividade. Classes que possuem mais atividades, por outro lado, dispõem de menos tempo para cada atividade, como é o caso da classe Atividade Doméstica, que por possuir 11 atividades, dispõe de uma média de 11 segundos para cada atividade.

O roteiro de atividades pré definido, que foi executado por cada indivíduo, pode ser conferido na tabela 8.

Tabela 8: Roteiro de atividades

Classe	Atividade	Local	Tempo
Alta Intensidade	Atividade física	Sala	120s
Andar	Andar	Sala	18s
Andar	Andar	Quarto	17 s
Andar	Andar	Cozinha	17s
Andar	Andar	Corredor	17s
Andar	Andar	Banheiro	17s
Andar	Andar	Escritório	17s
Andar	Andar	Área de Serviço	17s
Atividade Doméstica	Varrer	Sala	11s
Atividade Doméstica	Varrer	Quarto	11s
Atividade Doméstica	Varrer	Cozinha	11s
Atividade Doméstica	Varrer	Corredor	11s
Atividade Doméstica	Varrer	Banheiro	11s
Atividade Doméstica	Varrer	Escritório	11s
Atividade Doméstica	Varrer	Área de Serviço	11s
Atividade Doméstica	Arrumar a cama	Quarto	11s
Atividade Doméstica	Cozinhar	Cozinha	11s
Atividade Doméstica	Lavar louça	Cozinha	11s
Atividade Doméstica	Lavar roupa	Área de Serviço	10s
Baixa Intensidade	Escrever	Sala	20s
Baixa Intensidade	Escrever	Quarto	20s
Baixa Intensidade	Escrever	Escritório	20s
Baixa Intensidade	Usar computador	Sala	20s
Baixa Intensidade	Usar computador	Quarto	20s
Baixa Intensidade	Usar computador	Escritório	20s
Comer	Comer	Cozinha	120s
Domir	Dormir	Quarto	120s
Higiene Pessoal	Escovar dentes	Banheiro	60s
Higiene Pessoal	Lavar rosto	Banheiro	60s

## 5.3 CENÁRIOS E RESULTADOS

### 5.3.1 Cenário I - Dados de Movimentação

Neste cenário serão apresentados os resultados do reconhecimento de atividades humanas quando são utilizados apenas os dados de movimentação. Os resultados apresentados consideram uso do modelo

em um novo indivíduo, ou seja, sem que o modelo seja treinado com os dados do indivíduo. Serão utilizados os dados de 4 dos indivíduos monitorados como dados de treino, e os dados do indivíduo restante como dados de teste.

### 5.3.1.1 Validação Cruzada

Foram executados testes com 3 diferentes algoritmos: *Extra Trees*, *Gradient Boosting* e *Random Forest*. A tabela 9 apresenta um comparativo da precisão do modelo para os dados de treino utilizando os algoritmos citados.

Tabela 9: Comparativo Validação Cruzada - Cenário I

Algoritmo	Precisão
<i>Extra Trees</i>	95,32%
<i>Gradient Boosting</i>	94,94%
<i>Random Forest</i>	94,68%

Como citado anteriormente, o algoritmo *Extra Trees* - que apresentou os melhores resultados durante os testes - foi o selecionado para a tarefa de identificação de atividades.

### 5.3.1.2 Importância das Características

Na Figura 16 podemos ver a importância individual de cada característica para o modelo. É interessante observar que as características mais complexas (Amplitude Interquartil, Entropia, Signal Magnitude Area e Correlação de sinais), são as que apresentam menor importância para o modelo. Outro ponto interessante a ser observado é o fato das 5 características mais relevantes para o modelo serem referentes ao eixo Y do acelerômetro.




Figura 16: Importância das Características - Cenário I

Fonte: elaborado pelo autor.

### 5.3.1.3 Precisão do Modelo

Apesar da alta precisão do modelo na validação cruzada (95,32%), ocorreu uma queda considerável quando o modelo é aplicado para dados de teste, obtendo uma precisão de 81,16%. Um ponto interessante a ser observado diz respeito a classe com maior índice de erro - higiene pessoal -, ser uma das que está mais fortemente ligada a uma localização dentro de casa - banheiro. Espera-se portanto, que com a adição dos dados de localização, o modelo tenha uma melhora na sua precisão.




Figura 17: Matriz de Confusão - Cenário I

Fonte: elaborado pelo autor.

### 5.3.2 Cenário II(a) - Dados de Movimentação e Localização

Neste cenário serão apresentados os resultados do reconhecimento de atividades humanas utilizando dados de movimentação e localização. Neste cenário são repetidos exatamente os mesmos procedimentos realizados no cenário I.

Foi identificado uma baixa precisão nos dados de localização *in-door* para ambientes que não possuíam dispositivos *Bluetooth* (Corredor, Banheiro e Área de Serviço). Ambientes com dispositivos *Bluetooth* alcançaram uma precisão próxima de 95% enquanto ambientes sem dispositivos *Bluetooth* apresentaram precisão próxima a 30%.

#### 5.3.2.1 Validação Cruzada

A tabela 10 apresenta um comparativo da precisão do modelo para os dados de teste utilizando os diferentes algoritmos.

Tabela 10: Comparativo Validação Cruzada - Cenário II(a)

Algoritmo	Precisão
<i>Extra Trees</i>	94,68%
<i>Gradient Boosting</i>	95,26%
<i>Random Forest</i>	95,58%

Um fato interessante a ser observado é que a precisão do algoritmo *Extra Trees* diminuiu, enquanto a precisão dos outros 2 algoritmos teve um leve aumento. Neste cenário, assim como o anterior, o algoritmo *Extra Trees* foi o selecionado para a tarefa de identificação de atividades.

### 5.3.2.2 Importância das Características

Na Figura 18 podemos ver a importância individual de cada característica para o modelo. Os resultados obtidos são muito semelhantes ao cenário I, porém a característica mais importante neste cenário foi a característica referente ao Lugar\_x1. Um ponto interessante é que as outras características referentes a Lugar ocupam posição mais distantes, 6º e 7º lugar das características mais importantes.




Figura 18: Importância das Características - Cenário II(a)

Fonte: elaborado pelo autor.

### 5.3.2.3 Precisão do Modelo

Apesar da precisão do modelo na validação cruzada (94,68%) ter diminuído em relação ao Cenário I, tivemos uma aumento considerável quando aplicamos o modelo nos dados de teste, obtendo uma precisão de 92,59%. Um dos pontos que contribuiu muito para o aumento desta precisão foi a correta predição de um maior número de atividades relacionadas a higiene. A matriz de confusão para o Cenário II(a) pode ser vista na Figura 19.




Figura 19: Matriz de Confusão - Cenário II(a)

Fonte: elaborado pelo autor.

### 5.3.3 Cenário II(b) - Dados de Localização Sintéticos

Devido a baixa precisão do localizador *indoor* para ambientes críticos, como é o caso do Banheiro, decidiu-se repetir os procedimentos do Cenário II(a), porém, com dados de localização sintéticos no lugar dos dados provenientes do sistema de localização do modelo. Foi



considerado uma precisão de 100% para a localização *indoor* para os dados sintéticos.

### 5.3.3.1 Validação Cruzada

A tabela 11 apresenta um comparativo da precisão do modelo para os dados de teste utilizando diferentes algoritmos.

Tabela 11: Comparativo Validação Cruzada - Cenário II(b)

Algoritmo	Precisão
<i>Extra Trees</i>	99,35%
<i>Gradient Boosting</i>	98,05%
<i>Random Forest</i>	98,77%

Fica claro que quando possuímos uma localização *indoor* perfeita a precisão do modelo aumenta de forma expressiva, aproximando-se do 100% nos 3 algoritmos utilizados. Este resultado comprova que as atividades domésticas estão de fato fortemente ligadas ao ambiente em que o indivíduo está.

### 5.3.3.2 Importância das Características

Na Figura 20 podemos ver a importância individual de cada característica para o modelo. Os resultados obtidos são muito semelhantes aos dos Cenários I e II(a). A grande diferença porém, está no fato das 3 características relacionadas à Localização serem as 3 características mais relevantes para o modelo.




Figura 20: Importância das Características - Cenário II(b)

Fonte: elaborado pelo autor.

### 5.3.3.3 Precisão do Modelo

No caso da localização *indoor* perfeita, a precisão do modelo na validação cruzada (99,35%) e quando aplicamos o modelo nos dados de teste (97,56%) são muito mais próximas, ambas se aproximando dos 100%. A matriz de confusão para o Cenário II(b) pode ser vista na Figura 21.




Figura 21: Matriz de Confusão - Cenário II(b)

Fonte: elaborado pelo autor.

## 5.4 CONSIDERAÇÕES DO CAPÍTULO

Os testes experimentais apresentaram resultados que comprovam a eficácia do modelo, podendo este ser utilizado para a geração de uma rotina padrão do usuário monitorado. Com uma rotina padrão definida, pode-se então classificar com maior confiabilidade quais dados representam uma situação crítica.

Quando comparamos os resultados obtidos nas validações cruzadas com dados de testes nos diferentes cenários, observamos uma diferença considerável no cenário 1. Uma alternativa a ser considerada para reduzir essa diferença seria treinar o modelo utilizando também as atividades do usuário a ser monitorado.

Durante a execução dos testes, algumas dificuldades foram encontradas em relação a utilização do *Bluetooth* como tecnologia de comunicação. A identificação de localização *indoor*, por exemplo, apresenta baixa precisão para alguns cômodos, fator que levou a criação de uma variação do cenário 2 utilizando dados sintéticos de localização.

Com relação a importância das características, fica claro a forte relação entre atividade realizada e localização *indoor*. Quando consideramos os dados sintéticos de localização, temos as 3 features de localização como as mais importantes para o modelo, sendo essas pelo menos 2 vezes mais importantes que as demais características.



## 6 CONCLUSÕES E TRABALHOS FUTUROS

Com este trabalho foi possível identificar o estado da arte dos Ambientes Domiciliares Assistidos, assim como do campo de reconhecimento de atividade humana. Ficou clara a falta de padrão existente na literatura referente a este contexto e a vasta gama de abordagens utilizadas. Para este trabalho, decidiu-se utilizar uma abordagem onde o indivíduo monitorado carrega apenas um único sensor corporal, e dados de localização e movimentação são enviados para o sistema computacional para a predição das atividades.

O modelo mostrou-se eficaz para o reconhecimento de atividades humanas para os dados de teste, apresentando precisões de 81,16% quando utilizados apenas dados de movimentação, 92,59% quando utilizados dados de movimentação e localização e 97,56% quando utilizados dados de movimentação e dados sintéticos de localização.

Durante os testes foram identificados alguns problemas de comunicação *Bluetooth*, principalmente para o sistema de localização *indoor*, o que levou a uma baixa precisão para este sistema em ambientes onde não haviam dispositivos *Bluetooth* (Corredor, Banheiro e Área de Serviço). Para lidar com este problema, utilizando a mesma abordagem, seria necessário a instalação de dispositivos *Bluetooth* em todos os ambientes monitorados, o que seria inviável para o público em geral. Mesmo com o problema da comunicação a importância da localização para o reconhecimento de atividade humana foi comprovado ao utilizarmos dados sintéticos de localização.

O posicionamento dos dispositivos *Bluetooth* também foi um ponto chave para o sucesso da pesquisa. Foi necessário testar diversas disposições dos dispositivos para se chegar a resultados satisfatórios. Obstruções no caminho entre o dispositivo *Bluetooth* e o sensor corporal, por menor que sejam, podem ter um grande impacto nas medições de intensidade de sinal.

O uso do acelerômetro como sensor principal para a identificação de atividades deu-se principalmente por seu baixo consumo energético e suas pequenas dimensões, o que favorece a não intrusividade, garantindo uma vida com qualidade e independência para os indivíduos monitorados.

Com os resultados da pesquisa, são sugeridas abaixo algumas melhorias que poderão ser tratadas em trabalhos futuros:

- Estudar outras tecnologias de comunicação a fim de diminuir o impacto das falhas de comunicação dos dispositivos *Bluetooth*;

- Identificar outras técnicas de localização *indoor* que apresentem resultados mais consistentes. São recomendadas especificamente técnicas baseadas em RFID ou intensidade do sinal WIFI como possíveis soluções;
- Aplicação de um filtro de Qualidade de Contexto para definir quais dados devem ser armazenados ou descartados;
- Implementar um sistema capaz de gerar a rotina do indivíduo monitorado a partir das suas atividades e gerar alertas caso esta rotina seja quebrada.

## REFERÊNCIAS

- AKYILDIZ, I. et al. Wireless sensor networks: a survey. *Computer Networks*, v. 38, n. 4, p. 393 – 422, 2002.
- AMARAL, W. do; DANTAS, M. Um modelo de reconhecimento de atividades humanas baseado no uso de acelerômetro com qoc. In: *Workshop de Iniciação Científica do WSCAD 2017 (XVIII Simpósio em Sistemas Computacionais de Alto Desempenho)*. [S.l.: s.n.], 2017. p. 45 – 50. ISSN 2358-6613.
- ANGUITA, D. et al. A public domain dataset for human activity recognition using smartphones. In: *21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2013*. [S.l.: s.n.], 2013.
- ASHTON, K. That ‘internet of things’ thing. *RFiD Journal*, v. 22, n. 7, p. 97–114, 2009.
- ATALLAH, L. et al. Sensor positioning for activity recognition using wearable accelerometers. *IEEE Transactions on Biomedical Circuits and Systems*, v. 5, n. 4, p. 320–329, Aug 2011.
- BABAOGLU, O.; MARZULLO, K. Consistent global states of distributed systems: Fundamental concepts and mechanisms. *Distributed Systems*, v. 53, 1993.
- BAO, L.; INTILLE, S. S. Activity recognition from user-annotated acceleration data. In: \_\_\_\_\_. *Pervasive Computing: Second International Conference, PERVASIVE 2004, Linz/Vienna, Austria, April 21-23, 2004. Proceedings*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004. p. 1–17. ISBN 978-3-540-24646-6.
- BISHOP, C. M. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387310738.
- BONOMI, F. et al. Fog computing and its role in the internet of things. In: *Proceedings of the First Edition of the MCC Workshop on Mobile Cloud Computing*. New York, NY, USA: ACM, 2012. (MCC '12), p. 13–16. ISBN 978-1-4503-1519-7.

BUYAYA, R. et al. Cloud computing and emerging it platforms: Vision, hype, and reality for delivering computing as the 5th utility. *Future Generation Computer Systems*, Elsevier Science Publishers B. V., Amsterdam, Holanda, v. 25, n. 6, p. 599 – 616, 2009.

CHANDY, K. M.; LAMPORT, L. Distributed snapshots: Determining global states of distributed systems. *ACM Trans. Comput. Syst.*, ACM, New York, NY, USA, v. 3, n. 1, p. 63–75, 1985.

CHEVALIER, G. *LSTMs for Human Activity Recognition*. 2016. <<https://github.com/guillaume-chevalier/LSTM-Human-Activity-Recognition>>. Acesso em: 13/06/2017.

DAM, T. V.; LANGENDOEN, K. An adaptive energy-efficient mac protocol for wireless sensor networks. In: ACM. *Proceedings of the 1st international conference on Embedded networked sensor systems*. [S.l.], 2003. p. 171–180.

DIETTERICH, T. G. Ensemble methods in machine learning. In: \_\_\_\_\_. *Multiple Classifier Systems: First International Workshop, MCS 2000 Cagliari, Italy, June 21–23, 2000 Proceedings*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000. p. 1–15. ISBN 978-3-540-45014-6.

DOHR, A. et al. The internet of things for ambient assisted living. In: *Proceedings of the 2010 Seventh International Conference on Information Technology: New Generations*. Washington, DC, USA: IEEE Computer Society, 2010. (ITNG '10), p. 804–809. ISBN 978-0-7695-3984-3.

DWIYANTORO, A. P. J.; NUGRAHA, I. G. D.; CHOI, D. A simple hierarchical activity recognition system using a gravity sensor and accelerometer on a smartphone. *International Journal of Technology*, v. 7, n. 5, 2016. ISSN 2087-2100.

FORKAN, A. R. M. et al. A context-aware approach for long-term behavioural change detection and abnormality prediction in ambient assisted living. *Pattern Recognition*, Elsevier Science Inc., Nova Iorque, NY, USA, v. 48, n. 3, p. 628–641, 2015.

FU, K. *Sequential Methods in Pattern Recognition and Machine Learning*. [S.l.]: Elsevier Science, 1968. (Mathematics in Science and Engineering, v. 52). ISBN 9780080955599.



FUKUNAGA, K. *Introduction to statistical pattern recognition*. [S.l.]: Academic press, 2013.

GEURTS, P.; ERNST, D.; WEHENKEL, L. Extremely randomized trees. *Machine Learning*, v. 63, n. 1, p. 3–42, 2006. ISSN 1573-0565.

GOMEZ, C.; OLLER, J.; PARADELLS, J. Overview and evaluation of bluetooth low energy: An emerging low-power wireless technology. *Sensors*, Molecular Diversity Preservation International, v. 12, n. 9, p. 11734–11753, 2012.

GOODWIN, M.; ISLAND, U. of R. *Telemetric Assessment of Stereotypical Motor Movements in Children with Autism Spectrum Disorder*. [S.l.]: University of Rhode Island, 2008. ISBN 9780549633891.

HAK, M. Gad-el. *The MEMS Handbook*. [S.l.]: CRC Press, 2001. (Mechanical and Aerospace Engineering Series). ISBN 9781420050905.

HALLER, S.; KARNOUSKOS, S.; SCHROTH, C. Future internet — fis 2008. In: DOMINGUE, J.; FENSEL, D.; TRAVERSO, P. (Ed.). Berlin, Heidelberg: Springer-Verlag, 2009. cap. The Internet of Things in an Enterprise Context, p. 14–28. ISBN 978-3-642-00984-6.

HASSAN, Q. Demystifying cloud computing. *The Journal of Defense Software Engineering*, p. 16–21, 2011.

IBGE. *Projeção da População do Brasil por Sexo e Idade 2000-2060*. 2013. Revisão 2013.

KANG, H. G. et al. In situ monitoring of health in older adults: Technologies and issues. *Journal of the American Geriatrics Society*, Blackwell Publishing Inc, v. 58, n. 8, p. 1579–1586, 2010.

KARANTONIS, D. M. et al. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. *IEEE Transactions on Information Technology in Biomedicine*, v. 10, n. 1, p. 156–167, Jan 2006.

KHAN, A. M. et al. A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer. *IEEE Transactions on Information Technology in Biomedicine*, v. 14, n. 5, p. 1166–1172, Sept 2010.

KIM, Y. J.; KANG, B. N.; KIM, D. Hidden markov model ensemble for activity recognition using tri-axis accelerometer. In: *2015 IEEE International Conference on Systems, Man, and Cybernetics*. [S.l.: s.n.], 2015. p. 3036–3041.

KWAPISZ, J. R.; WEISS, G. M.; MOORE, S. A. Activity recognition using cell phone accelerometers. *SIGKDD Explor. Newsl.*, ACM, New York, NY, USA, v. 12, n. 2, p. 74–82, mar. 2011.

LEE, M.-W.; KHAN, A. M.; KIM, T.-S. A single tri-axial accelerometer-based real-time personal life log system capable of human activity recognition and exercise information generation. *Personal and Ubiquitous Computing*, v. 15, n. 8, p. 887–898, 2011. ISSN 1617-4917.

MANNINI, A. et al. Activity recognition using a single accelerometer placed at the wrist or ankle. *Medicine and Science in Sports and Exercise*, v. 45, n. 11, p. 2193–2203, 2013.

MANTYJARVI, J.; HIMBERG, J.; SEPPANEN, T. Recognizing human motion with multiple acceleration sensors. In: *2001 IEEE International Conference on Systems, Man and Cybernetics. e-Systems and e-Man for Cybernetics in Cyberspace (Cat.No.01CH37236)*. [S.l.: s.n.], 2001. v. 2, p. 747–752.

MATHIE, M. J. et al. Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement. *Physiological Measurement*, v. 25, n. 2, p. R1, 2004.

MAURER, U. et al. Activity recognition and monitoring using multiple sensors on different body positions. In: *Proceedings of the International Workshop on Wearable and Implantable Body Sensor Networks*. Washington, DC, EUA: IEEE Computer Society, 2006. (BSN '06), p. 113–116. ISBN 0-7695-2547-4.

MOESLUND, T. B.; HILTON, A.; KRÜGER, V. A survey of advances in vision-based human motion capture and analysis. *Comput. Vis. Image Underst.*, Elsevier Science Inc., Nova Iorque, NY, EUA, v. 104, n. 2, p. 90–126, 2006.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. *Foundations of machine learning*. [S.l.]: MIT press, 2012.

MURAO, K.; TERADA, T. A combined-activity recognition method with accelerometers. *Journal of Information Processing*, v. 24, n. 3, p. 512–521, 2016.

NOOR, M. H. M.; SALCIC, Z.; WANG, K. I.-K. Adaptive sliding window segmentation for physical activity recognition using a single tri-axial accelerometer. *Pervasive and Mobile Computing*, v. 38, n. Part 1, p. 41 – 59, 2017. ISSN 1574-1192.

PATEL, S. et al. A review of wearable sensors and systems with application in rehabilitation. *Journal of NeuroEngineering and Rehabilitation*, v. 9, n. 1, p. 21, 2012.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.

RASTOGI, R.; SHIM, K. Public: A decision tree classifier that integrates building and pruning. *Data Mining and Knowledge Discovery*, v. 4, n. 4, p. 315–344, 2000. ISSN 1573-756X.

RAVI, N. et al. Activity recognition from accelerometer data. In: *Proceedings of the 17th Conference on Innovative Applications of Artificial Intelligence - Volume 3*. [S.l.]: AAAI Press, 2005. (IAAI'05), p. 1541–1546. ISBN 1-57735-236-x.

SAFAVIAN, S. R.; LANDGREBE, D. A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 21, n. 3, p. 660–674, 1991. ISSN 0018-9472.

SCIKIT-LEARN. *Ensemble methods*. 2017.

<<http://scikit-learn.org/stable/modules/ensemble.html>>. Acesso em: 27/08/2017.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. *Understanding Machine Learning: From Theory to Algorithms*. [S.l.]: Cambridge University Press, 2014. (Understanding Machine Learning: From Theory to Algorithms). ISBN 9781107057135.

SIEKKINEN, M. et al. How low energy is bluetooth low energy? comparative measurements with zigbee/802.15. 4. In: IEEE. *Wireless Communications and Networking Conference Workshops (WCNCW), 2012 IEEE*. [S.l.], 2012. p. 232–237.

STEMM, M.; KATZ, R. H. Measuring and reducing energy consumption of network interfaces in hand-held devices. *IEICE*

*transactions on communications*, The Institute of Electronics, Information and Communication Engineers, v. 80, n. 8, p. 1125–1131, 1997.

STOJMENOVIC, I.; WEN, S. The fog computing paradigm: Scenarios and security issues. In: *2014 Federated Conference on Computer Science and Information Systems*. [S.l.: s.n.], 2014. p. 1–8.

TANENBAUM, A. S.; STEEN, M. v. *Distributed Systems: Principles and Paradigms (2Nd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006. ISBN 0132392275.

TINYCIRCUITS. *TinyDuino Overview*. 2017. Disponível em: <https://tinycircuits.com/pages/tinyduino-overview>. Acesso em: 11/01/2017.

WEBER, R. H.; WEBER, R. *Internet of Things: Legal Perspectives*. 1. ed. [S.l.]: Springer Publishing Company, Incorporated, 2010. ISBN 9783642117091.

YU, Z. et al. A decision tree method for building energy demand modeling. *Energy and Buildings*, v. 42, n. 10, p. 1637 – 1646, 2010. ISSN 0378-7788.

ZHU, C.; SHENG, W. Motion- and location-based online human daily activity recognition. *Pervasive Mob. Comput.*, Elsevier Science Publishers B. V., Amsterdam, Holanda, v. 7, n. 2, p. 256–269, 2011.

## APÊNDICE A - Artigo Publicado



**Título:** Um Modelo de Reconhecimento de Atividades Humanas Baseado no Uso de Acelerômetro com QoC.

**Evento:** Workshop de Iniciação Científica do XVIII Simpósio em Sistemas Computacionais de Alto Desempenho.

**Data:** Setembro de 2017

**Local:** Campinas/SP - Brasil

**Qualis:** B3

## Um Modelo de Reconhecimento de Atividades Humanas Baseado no Uso de Acelerômetro com QoC

Wagner D. do Amaral<sup>1</sup>, Mario A. R. Dantas<sup>1</sup>

<sup>1</sup>Departamento de Informática e Estatística (INE) – Universidade Federal de Santa Catarina (UFSC)

wagner.amaral@grad.ufsc.com, mario.dantas@ufsc.br

***Abstract.** This work presents a model proposal, entitled HARA (Human Activity Recognition with Accelerometer), which utilizes data related to the person location, movement and time. The model uses an accelerometer as its main sensor due to the low power consumption and small dimensions of this sensor. Identifying activities of an individual is particularly important because, in this way, it is possible to understand their individual routine, and based on that, one can identify abrupt changes in such routine, which may be related to the early stage of a disease. Aiming the efficiency of the model, the use of a filter for quality of context (QoC) is also proposed, in a way that data with low QoC value are dropped.*

***Resumo.** Este trabalho apresenta o modelo HARA (Human Activity Recognition with Accelerometer), para reconhecimento de atividades humanas a partir de dados de localização, movimentação e tempo. O modelo utiliza um acelerômetro como principal sensor devido ao baixo consumo energético e as pequenas dimensões deste sensor. Identificar atividades de um indivíduo é importante pois, desta forma, é possível compreender sua rotina individual, e baseado nisso, identificar mudanças bruscas, que podem estar relacionadas a estágios iniciais de uma doença. Visando a eficiência do modelo, também é proposto o uso de um filtro de qualidade de contexto, onde dados com baixo valor na qualidade de contexto (QoC) são descartados.*

### 1. Introdução

Segundo projeções do IBGE, o número de idosos - pessoas com mais de 60 anos - no Brasil em 2060, representará quase 34% da população do Brasil. Em números absolutos a estimativa é que o número de idosos praticamente triplique até 2060 [IBGE 2013].

Com este grande crescimento da população de idosos, vê-se a oportunidade e a necessidade da criação de condições que os garanta uma vida com qualidade e independência. Como solução, estão surgindo tecnologias que monitoram indivíduos em suas casas, os chamados ambientes domiciliares assistidos.

Um ambiente domiciliar assistido é composto por um conjunto heterogêneo de sensores corporais e de ambiente, que geram grandes volumes de dados. A qualidade dos dados, portanto, é a chave para a manutenção destes ambientes [Forkan et al. 2015]. Para lidar com este grande volume de dados e garantir que o modelo seja acessível, é necessário processamento de alto desempenho com arquiteturas de baixo custo, além da



implementação de um analisador de contexto que filtre os dados, descartando informações com pouco ou nenhum valor semântico.

Ambientes domiciliares assistidos tradicionais usam diversas técnicas para detecção de anormalidades, porém, de uma forma geral, detectam anormalidades somente quando elas ocorrem, o que muitas vezes está ligado ao estado avançado de uma doença [Forkan et al. 2015]. Neste tipo de sistema, não é possível prever anomalias com tempo hábil para que ações preventivas sejam tomadas, o que evitaria que a situação se torne crítica.

Para preencher esta lacuna deixada pelos ambientes domiciliares assistidos tradicionais, este trabalho propõe o modelo HARA (*Human Activity Recognition with Accelerometer*). Ao armazenar dados do posicionamento na residência, movimentação e tempo, é possível inferir as atividades diárias de um indivíduo, e assim entender sua rotina individual. Mudanças bruscas na rotina podem estar relacionadas ao estágio inicial de alguma doença, e a identificação de uma doença em sua etapa inicial geralmente representa maiores chances de um tratamento bem sucedido.

O modelo HARA utiliza um acelerômetro como principal sensor para o reconhecimento de atividades humanas devido ao baixo consumo energético e às pequenas dimensões deste sensor, favorecendo a não intrusividade, e garantindo assim uma maior qualidade de vida para o usuário monitorado. A adição da informação da localização *indoor* garante uma maior precisão para a identificação das atividades, uma vez que atividades humanas e localização estão fortemente correlacionadas em ambientes internos [Zhu and Sheng 2011].

Este trabalho de pesquisa está dividido da seguinte forma: na seção 2 é apresentada uma revisão da literatura e alguns trabalhos correlatos, a proposta está descrita na seção 3. Os dados preliminares do modelo são apresentados na seção 4, e as conclusões e recomendações para trabalhos futuros estão descritas na seção 5

## 2. Revisão Bibliográfica e Trabalhos Correlatos

Recentemente, muitos artigos passaram a abordar o tema de ambientes assistidos. Por se tratar de um conceito relativamente novo, poucos padrões são encontrados na literatura. Alguns trabalhos, como [Mannini et al. 2013], utilizam apenas o único acelerômetro para o reconhecimento das atividades. Outros trabalhos, como [Dwiyantoro et al. 2016], [Murao and Terada 2016] e [Kim et al. 2015], utilizam diversos sensores para a mesma finalidade.

O uso de sensores corporais é amplamente utilizado nesta área, porém outras abordagens também são encontradas na literatura, como a utilização de imagens para o reconhecimento das atividades. Este é o caso de trabalhos como [Maurer et al. 2006].

Para os sensores corporais, a posição do corpo onde o dispositivo será acoplado possui grande importância. Apesar de também não existir um padrão sobre onde os sensores devem ser posicionados, alguns dos lugares mais comuns são: peito, pulso, tornozelo e cintura. Em [Atallah et al. 2011] é realizado um estudo para determinar o melhor posicionamento para sensores corporais.

Para melhor compreender o estado atual da pesquisa nesta área, realizou-se uma revisão da literatura. Foram realizadas buscas pelo termo "*activity recognition AND acce-*

rometer” no título de documentos de 4 bases de dados: *IEEE Xplorer*, *ProQuest*, *Scopus* e *Web of Science*. Todas as buscas foram realizadas em janeiro de 2017, sendo excluídos documentos redigidos em idioma diferente do português, inglês ou espanhol, documentos sem o texto completo disponível e documentos repetidos. Como resultado, foi encontrado um total de 253 artigos entre as 4 bases de dados, destes, 76 foram selecionados para uma análise mais detalhada.

### 2.1. Comparativo das Abordagens

A Tabela 1 apresenta uma comparação entre as abordagens utilizadas em alguns dos trabalhos selecionados durante a revisão da literatura.

**Tabela 1. Comparativo de Trabalhos de Pesquisa**

Referência	Sensor	Localização do sensor	Método de classificação
[Mannini et al. 2013]	Acelerômetro	Pulso ou Tornozelo	Support Vector Machine
[Dwiyantoro et al. 2016]	Acelerômetro e Sensor de gravidade (smartphone)	Bolso frontal da calça	Dynamic Time Warping e K-Nearest Neighbors
[Murao and Terada 2016]	Múltiplos acelerômetros	Ambos pulsos e tornozelos e quadril	Dynamic Time Warping e Support Vector Machine
[Kim et al. 2015]	Acelerômetro e Giroscópio (smartphone)	Cintura	Hidden Markov Model

## 3. Proposta

Este trabalho propõe o modelo HARA, um modelo de análise de dados com a finalidade de inferir as atividades realizadas por um indivíduo monitorado dentro de sua casa. O sistema ainda considera a abordagem de QoC, visando uma avaliação da qualidade de contexto dos dados recebidos e que possa levar a uma decisão do que deve ser descartado e o que deve dar origem a alertas. Uma visão geral do modelo pode ser observada na Figura 1.

### 3.1. Obtenção dos Dados

Como citado anteriormente, serão obtidos dados de posicionamento, movimentação e tempo. Para a obtenção destes dados, um dispositivo deverá ser montado a partir de uma placa de processamento *Tinyduino*, acoplando a ela os *shields* de acelerômetro e BLE (*Bluetooth Low Energy*). Este dispositivo deverá ser posicionado no corpo do indivíduo a ser monitorado. Segundo [Atallah et al. 2011], para a identificação de atividades como andar e afazeres domésticos, os melhores lugares para posicionar o acelerômetro seriam o pulso ou o peito. Levando em consideração a comodidade para o indivíduo monitorado, decidiu-se acoplar o dispositivo, de dimensões 20mm x 20mm x 16.8mm, em seu pulso.




Figura 1. HARA - Visão Geral.

A escolha dos *shields* de acelerômetro e BLE para incorporar o sensor corporal levou em consideração o baixo consumo energético destes *shields*. O acelerômetro também apresenta-se como uma alternativa ideal para o modelo proposto devido a suas pequenas dimensões, favorecendo a não intrusividade.

Para os dados de movimentação, serão utilizadas as informações do acelerômetro. Para os dados de localização, o módulo BLE ficará responsável por detectar a intensidade de sinal dos dispositivos disponíveis para pareamento. Haverá um dispositivo BLE para cada cômodo da casa, e as intensidades serão comparadas para determinar a posição do indivíduo na casa. A cada 200ms estes dados serão enviados, através do BLE, do *Tinyduino* para um *Raspberry Pi 3*, dispositivo responsável pelo processamento destes dados, e inclusão da informação de tempo.

### 3.2. Predição das Atividades

Após a obtenção e transmissão dos dados de movimentação e localização para o *Raspberry Pi 3*, com a adição da informação de tempo, será realizado um processo de predição para inferência de qual atividade o indivíduo monitorado está realizando. Para a implementação desta predição, a técnica utilizada será o Modelo Oculto de Markov (HMM) [Blunsom 2004].

A escolha pelo HMM se deve a esta técnica ser capaz de representar uma quantidade infinita de sequência possíveis, através de uma quantidade finita de estados. Assim, a técnica se mostra ideal para a necessidade do modelo proposto, representar uma sequência qualquer de ações executadas por um indivíduo, por meio de uma quantidade limitada de estados.

### 3.3. Qualidade de Contexto (QoC)

É proposto também, que o modelo avalie a qualidade de contexto dos dados recebidos e decida o que deve ser descartado e o que deve dar origem a alertas. Para o cálculo do QoC, será utilizada a abordagem proposta por [Nazário et al. 2014], na qual cinco parâmetros são considerados para determinar o resultado deste cálculo. São eles: *Completeness*, *Coverage*, *Precision*, *Up-to-dateness* e *Significance*. Cada um dos parâmetros possui valor entre 0 e 1, e é realizada uma média entre eles, excluindo o parâmetro *Significance*. Este último parâmetro possuirá valor 1 se os valores medidos são válidos, mas não esperados, indicando um caso onde a criação de um alerta é necessária, ou 0, nos demais casos, indicando que os dados podem ser descartado.

#### 4. Ambiente e Resultados Experimentais

Nesta seção, serão apresentados os dados preliminares do modelo HARA. Inicialmente é realizado um experimento para a leitura dos dados do acelerômetro, que em seguida passam pelo filtro QoC. Para esta etapa, foram monitorados os movimentos de 5 indivíduos, durante uma hora cada.

A Figura 2 apresenta os valores lidos durante 35 segundos, pelo acelerômetro ( $\pm 2g$ ) acoplado ao pulso de um dos indivíduo, enquanto este realizava atividades em sua própria casa.




Figura 2. Aceleração Referente a Sequência de Atividades.

Através de uma análise do gráfico, é possível observar que durante a sequência de atividades realizadas, os valores lidos pelo acelerômetro vão se alterando, porém, fica claro o quão difícil e ineficaz seria uma identificação manual destas atividades. Com isso, temos a importância do modelo HARA, que se propõe a identificar instantaneamente a atividade realizada pelo indivíduo.

A Tabela 2 expõe dados referentes a aplicação do filtro QoC nos dados recebidos durante os 35 segundos de monitoramento. Este filtro é responsável por garantir a qualidade dos dados. O parâmetro *Significance* não foi considerado para este experimento preliminar devido a ausência de valores de referência.

Tabela 2. Aplicação de filtro QoC

Situação	Quantidade
Sucesso	172
Filtrado	3
<b>Total</b>	<b>175</b>

#### 5. Conclusões e Trabalhos Futuros

Este trabalho apresentou um modelo de reconhecimento de atividades humanas, através do uso de sensor corporal para a captação de dados de movimentação e localização, além do tempo. O modelo também considera o uso da abordagem de QoC, visando uma avaliação da qualidade dos dados recebidos, levando a decisão do que deve ser descartado e o que deve dar origem a alertas.

O uso do acelerômetro como sensor principal para a identificação de atividades, se deu principalmente por seu baixo consumo energético e suas pequenas dimensões, o que favorece a não intrusividade.

Para trabalhos futuros é sugerido a comparação da eficiência entre diferentes tecnologias de comunicação, como o *bluetooth* 4.0 clássico, ou *ZigBee*. Outra comparação possível diz respeito a técnica de classificação. Com base na revisão da literatura, visto na seção 2, observou-se que quase 50% dos trabalhos selecionados utilizam algoritmos de árvore de decisão ou *Support Vector Machine*. Desta forma, a comparação entre a utilização do Modelo Oculto de Markov com os algoritmos citados, também seria interessante.

### Referências

- Atallah, L., Lo, B., King, R., and Yang, G. Z. (2011). Sensor positioning for activity recognition using wearable accelerometers. *IEEE Transactions on Biomedical Circuits and Systems*, 5(4):320–329.
- Blunsom, P. (2004). Hidden markov models. *Lecture notes, August*, 15:18–19.
- Dwiyantoro, A. P. J., Nugraha, I. G. D., and Choi, D. (2016). A simple hierarchical activity recognition system using a gravity sensor and accelerometer on a smartphone. *International Journal of Technology*, 7(5).
- Forkan, A. R. M., Khalil, I., Tari, Z., Foufou, S., and Bouras, A. (2015). A context-aware approach for long-term behavioural change detection and abnormality prediction in ambient assisted living. *Pattern Recognition*, 48(3):628–641.
- IBGE (2013). Projeção da população do brasil por sexo e idade 2000-2060. Revisão 2013.
- Kim, Y. J., Kang, B. N., and Kim, D. (2015). Hidden markov model ensemble for activity recognition using tri-axis accelerometer. In *2015 IEEE International Conference on Systems, Man, and Cybernetics*, pages 3036–3041.
- Mannini, A., Intille, S. S., Rosenberger, M., Sabatini, A. M., and Haskell, W. (2013). Activity recognition using a single accelerometer placed at the wrist or ankle. *Medicine and Science in Sports and Exercise*, 45(11):2193–2203.
- Maurer, U., Smailagic, A., Siewiorek, D. P., and Deisher, M. (2006). Activity recognition and monitoring using multiple sensors on different body positions. In *Proceedings of the International Workshop on Wearable and Implantable Body Sensor Networks, BSN '06*, pages 113–116, Washington, DC, EUA. IEEE Computer Society.
- Murao, K. and Terada, T. (2016). A combined-activity recognition method with accelerometers. *Journal of Information Processing*, 24(3):512–521.
- Nazário, D. C., Tromel, I. V. B., Dantas, M. A. R., and Todesco, J. L. (2014). Toward assessing quality of context parameters in a ubiquitous assisted environment. In *2014 IEEE Symposium on Computers and Communications (ISCC)*, pages 1–6, Madeira, Portugal. IEEE Computer Society.
- Zhu, C. and Sheng, W. (2011). Motion- and location-based online human daily activity recognition. *Pervasive Mob. Comput.*, 7(2):256–269.



## **APÊNDICE B – Código Fonte**





## B.1 DETECTAR INTENSIDADE DE SINAL

rssi.py

```

1  import os
2  import re
3  import mysql.connector
4  import ntplib
5  import datetime
6  import getpass
7  import subprocess
8  import time
9
10 database = mysql.connector.connect(user='root',
   ↪ password='',
11                                     host='127.0.0.1',
12                                     database='hara')
13 cursor = database.cursor()
14
15 c = ntplib.NTPClient()
16
17 lescan = "sudo hcitool lescan --duplicates 1>
   ↪ /dev/null &"
18 hcidump = "sudo timeout 1 hcidump -a"
19 subprocess.Popen(lescan, shell=True)
20
21 non_decimal = re.compile(r'[^\d.]+')
22
23 while(True):
24     time.sleep(1)
25     response = os.popen(hcidump).read()
26     rssi = re.findall("RSSI: -\d+", response)
27
28     if(len(rssi) > 0):
29         rssi = "-" + non_decimal.sub('', rssi[-1])

```

```

30         add_rssi = ("INSERT INTO rssi "
31                     "(strength, device, created_at) "
32                     "VALUES (%s, %s, %s)")
33
34         response = c.request('europa.pool.ntp.org',
↪ version=3)
35         created_at =
↪ datetime.datetime.fromtimestamp(response.tx_time)
36
37         data_rssi = (rssi, getpass.getuser(),
↪ created_at)
38
39         cursor.execute(add_rssi, data_rssi)
40         database.commit()

```

## B.2 PREDIÇÃO DA LOCALIZAÇÃO

location\_predict.py

```

1  import mysql.connector
2  import numpy as np
3  import pandas as pd
4  from sklearn.neighbors import KNeighborsClassifier
5  import time
6
7  database = mysql.connector.connect(user='root',
↪ password='',
8                                     host='127.0.0.1',
9                                     database='hara')
10 cursor = database.cursor(buffered=True)
11
12 location_array = ['sala', 'quarto', 'banheiro',
↪ 'escritorio', 'corredor', 'cozinha',
↪ 'area_de_servico']

```

```

13 device_array = ['adelaide', 'brisbane', 'perth',
14 ↪ 'sydney']
15
16
17 train = {}
18
19 for location in location_array:
20     query = ("SELECT strength, device FROM rssi_train
21     ↪ WHERE location = '%s'" % location)
22     cursor.execute(query)
23
24     for (strength, device) in cursor:
25         if location in train:
26             if device in train[location]:
27                 train[location][device].
28 ↪ append(strength)
29             else:
30                 train[location][device] = [strength]
31         else:
32             dev = {device: [strength]}
33             train[location] = dev
34
35
36 data = {}
37
38 for key in device_array:
39     data[key] = []
40     data['class'] = []
41
42 for location_key in train:
43     i = -1
44
45     for device_key in train[location_key]:
46         if i == -1:
47             i = len(train[location_key][device_key])
48         else:

```

```

43         if len(train[location_key][device_key]) <
↳ i:
44             i =
↳ len(train[location_key][device_key])
45
46     for device_key in train[location_key]:
47         train[location_key][device_key] =
↳ train[location_key][device_key][0:i]
48         data[device_key].extend(train[location_key]
↳ [device_key])
49         data['class'].append(location_key)
50
51 df = pd.DataFrame(data=data)
52
53 location_mapping = {location_array[0]: 0,
↳ location_array[1]: 1, location_array[2]: 2,
54                     location_array[3]: 3,
↳ location_array[4]: 4, location_array[5]: 5,
55                     location_array[6]: 6}
56
57 for key, value in location_mapping.items():
58     df.loc[df['class'] == key, 'class'] = value
59
60 y_train = df.loc[:, ['class']]
61 X_train = df.loc[:, device_array]
62
63 knn = KNeighborsClassifier(n_neighbors=3)
64 knn.fit(X_train, y_train.values.ravel())
65
66 data = {}
67
68 while(True):
69     time.sleep(1)

```

```

70     query = ("SELECT strength, device FROM rssi ORDER
↳ BY id DESC LIMIT 12")
71
72     cursor.execute(query)
73
74     for (strength, device) in cursor:
75         if device in data:
76             data[device].append(strength)
77         else:
78             data[device] = [strength]
79
80     for key in data:
81         data[key] = [np.mean(data[key])]
82
83     data['sydney'] = [-20]
84
85     df = pd.DataFrame(data=data)
86     X_test = df.loc[:,device_array]
87
88     pred = knn.predict(X_test)
89
90     current_location = ("INSERT INTO current_location
↳ (location) VALUES ('%s')" % pred[0])
91     cursor.execute(current_location)
92     database.commit()

```

### B.3 SENSOR CORPORAL - DADOS DE MOVIMENTAÇÃO acc.ino

```

1  #include <Wire.h>
2  #include "BMA250.h"
3  #include <SPI.h>
4  #include <STBLE.h>
5

```

```

6  BMA250 accel;
7
8  #ifndef BLE_DEBUG
9  #define BLE_DEBUG true
10 #endif
11
12 #if defined (ARDUINO_ARCH_AVR)
13 #define SerialMonitorInterface Serial
14 #elif defined(ARDUINO_ARCH_SAMD)
15 #define SerialMonitorInterface SerialUSB
16 #endif
17
18 uint8_t ble_rx_buffer[21];
19 uint8_t ble_rx_buffer_len = 0;
20 bool result;
21 uint8_t ble_connection_state = false;
22 #define PIPE_UART_OVER_BTLE_UART_TX_TX 0
23
24 void setup() {
25     SerialMonitorInterface.begin(9600);
26     Wire.begin();
27     accel.begin(BMA250_range_2g,
↳ BMA250_update_time_64ms);
28     BLEsetup();
29 }
30
31 void loop() {
32     result = aci_loop();
33
34     if (ble_rx_buffer_len) { //Check if data is
↳ available
35         if(result) {
36             accel.read();//This function gets new data from
↳ the accelerometer

```

```

37
38     String msg = String(accel.X);
39     msg += ",";
40     msg += String(accel.Y);
41     msg += ",";
42     msg += String(accel.Z);
43     msg += "$";
44
45     uint8_t sendBuffer[15];
46     uint8_t length = 15;
47
48     msg.getBytes(sendBuffer, 15);
49
50     ↪ lib_aci_send_data(PIPE_UART_OVER_BTLE_UART_TX_TX,
51     ↪ sendBuffer, length);
52
53     delay(200);
54 }
55 else {
56     ble_rx_buffer_len = 0;
57 }
58 }

```

#### B.4 UNE DADOS DE MOVIMENTAÇÃO E LOCALIZAÇÃO merge\_data.py

```

1  # -*- coding: utf-8 -*-
2
3  import pexpect
4  import mysql.connector
5

```

```

6  database = mysql.connector.connect(user='root',
   ↪  password='',
7                                     host='127.0.0.1',
8                                     database='hara')
9  cursor = database.cursor(buffered=True)
10
11  DEVICE = "CE:19:A1:97:B3:24"
12  error = 0
13
14  gatttool = pexpect.spawn("gatttool -t random -b {0}
   ↪  -I".format(DEVICE))
15
16  def connect():
17      gatttool.sendline("connect")
18      gatttool.expect("Connection successful",
   ↪  timeout=2)
19      print("Connected!")
20
21  def configure():
22      gatttool.sendline("char-write-req 0x0011 0100")
23      gatttool.sendline("char-write-cmd 0x000e
   ↪  537461727421")
24
25  def try_connection():
26      try:
27          connect()
28          configure()
29      except Exception:
30          print("Erro ao conectar!")
31          try_connection()
32
33  try_connection()
34
35  while(True):

```



```

36     if error > 9:
37         try_connection()
38         error = 0
39
40     try:
41         gatttool.expect("Notification handle = 0x0010
↳ value: ", timeout=1)
42         gatttool.expect("\r\n", timeout=1)
43
44         response = gatttool.before
45         response =
↳ bytearray.fromhex(response).decode()
46         position = response.index('$')
47
48         query = ("SELECT location FROM
↳ current_location ORDER BY id DESC LIMIT 1")
49         cursor.execute(query)
50
51         merge_data = response[0:position] + ',' +
↳ cursor.fetchall()[0][0]
52
53         sensor_data = ("INSERT INTO sensor_data
↳ (location) VALUES ('$s')" % merge_data)
54         cursor.execute(sensor_data)
55         database.commit()
56
57         error = 0
58     except Exception:
59         print("Dados indisponiveis.")
60         error += 1

```

## B.5 PREDIÇÃO DA ATIVIDADE

hara\_predict.py

```
1  # coding: utf-8
2
3  # ## Imports
4
5  # In[1]:
6
7  import numpy as np
8  import pandas as pd
9  import math
10 import scipy.stats
11 from statistics import mode
12 from scipy.stats.stats import pearsonr
13 from sklearn.model_selection import StratifiedKFold
14 from sklearn.model_selection import train_test_split
15 from sklearn.ensemble import RandomForestClassifier,
16     ↪ ExtraTreesClassifier, AdaBoostClassifier,
17     ↪ GradientBoostingClassifier, BaggingClassifier
18 from sklearn.neighbors import KNeighborsClassifier
19 from sklearn.model_selection import ShuffleSplit
20 from sklearn.model_selection import KFold
21 from sklearn.model_selection import cross_val_score
22 from sklearn.model_selection import cross_val_predict
23 from sklearn import metrics
24 from sklearn.svm import SVC
25 import matplotlib.pyplot as plt
26 from sklearn import svm
27 import random
28 import mysql.connector
29
30 # ## Database Connect
```

```
30
31 # In[2]:
32
33 database = mysql.connector.connect(user='root',
34     ↪ password='',
35                                     host='127.0.0.1',
36                                     database='hara')
37
38
39 # ## Define lista de atividades
40
41 # In[3]:
42
43 activity_list = [
44     "alta_intensidade",
45     "andar",
46     "atividades_domesticas",
47     "baixa_intensidade",
48     "comer",
49     "dormir",
50     "higiene"
51 ]
52
53
54 # ## Signal Magnitude Area
55
56 # In[4]:
57
58 def sma(x, y, z):
59     sum_value = 0
60
61     for i in range(0, len(x)):
```

```

62         sum_value += (abs(x[i]) + abs(y[i]) +
↪      abs(z[i]))
63
64     return sum_value / len(x)
65
66
67     # ## Entropy
68
69     # In[5]:
70
71     def entropy(array):
72         array = [-x if x < 0 else x for x in array]
73
74         return scipy.stats.entropy(array)
75
76
77     # ## Correlation
78
79     # In[6]:
80
81     def correlation(a, b):
82         value = pearsonr(a, b)[0]
83
84         if (np.isnan(value)):
85             return 0
86         else:
87             return value
88
89
90     # ## Divide dados em intervalos de 5 segundos
91
92     # In[7]:
93
94     def split_5s(array):

```

```

95     array_5s = [[], [], [], []]
96
97     for axis in range(0, len(array)):
98         for item in array[axis]:
99             i = 0
100
101             for j in
↪     range(0, math.ceil((len(item)-25)/10)+1):
102                 if (i+25 > len(item)):
103                     i -= i+25 - len(item)
104
105                     array_5s[axis].append(item[i:i+25])
106                     i += 10
107
108     return array_5s
109
110
111     ### Define Localização
112
113     # In[8]:
114
115     def set_location(array):
116         value = mode(array)
117
118         return(bin(value)[2:].rjust(3, '0'))
119
120
121     ### Define as features
122     #
123     # * Mean
124     # * Standard deviation
125     # * Median
126     # * Maximun value
127     # * Minimun value

```

```

128 # * Energy
129 # * Interquartile range
130 # * Entropy
131 # * Signal magnitude area
132 # * Correlation(X,Y)
133 # * Correlation(X,Z)
134 # * Correlation(Y,Z)
135
136 # In[9]:
137
138 def set_features(result, array_5s, activity):
139     for i in range(0,len(array_5s[0])):
140         partial_values = []
141
142         for item in array_5s[:-1]:
143             partial_values.append(np.mean(item[i]))
144             partial_values.append(np.std(item[i]))
145             partial_values.append(np.median(item[i]))
146             partial_values.append(np.amax(item[i]))
147             partial_values.append(np.amin(item[i]))
148             partial_values.append(sum([i ** 2 for i
↳ in item[i]]))
149
↳ partial_values.append(np.subtract(*np.percentile(
↳ item[i], [75, 25])))
150             partial_values.append(entropy(item[i]))
151
152             partial_values.append(sma(array_5s[0][i],
↳ array_5s[1][i], array_5s[2][i]))
153
↳ partial_values.append(correlation(array_5s[0][i],
↳ array_5s[1][i]))

```

```

154     ↪ partial_values.append(correlation(array_5s[0][i],
155     ↪ array_5s[2][i]))
156
157     ↪ partial_values.append(correlation(array_5s[1][i],
158     ↪ array_5s[2][i]))
159
160         location = set_location(array_5s[3][i])
161
162         partial_values.append(location[2])
163         partial_values.append(location[1])
164         partial_values.append(location[0])
165         partial_values.append(activity)
166
167         result.append(partial_values)
168
169     return(result)
170
171     # ## Calcula os valores da features para cada
172     ↪ intervalo de atividade
173
174     # In[10]:
175
176     def calc_features(users):
177         result = []
178
179         for activity in activity_list:
180             query = ("SELECT data, specific_activity FROM
181             ↪ sensor_data WHERE activity = '" + activity + "'
182             ↪ AND user IN (" + ",".join(map(str, users)) + ")")
183             cursor.execute(query)
184             response = []

```

```

181     base_activity = ''
182
183     for data, specific_activity in cursor:
184         if base_activity == '':
185             base_activity = specific_activity
186             response.append([])
187
188         if base_activity != specific_activity:
189             base_activity = specific_activity
190             response.append([])
191
192     response[-1].append(eval(data))
193
194     array = [[], [], [], []]
195
196     for block in response:
197         for i in range(0,4):
198             array[i].append([item[i] for item in
↪ block])
199
200     array_5s = split_5s(array)
201     result = set_features(result, array_5s,
↪ activity)
202
203     return result
204
205
206 # In[11]:
207
208 def set_df(result):
209     header = ['Mean X', 'STD X', 'Median X', 'Max X',
↪ 'Min X', 'Energy X', 'IQR X', 'Entropy X',
210             'Mean Y', 'STD Y', 'Median Y', 'Max Y',
↪ 'Min Y', 'Energy Y', 'IQR Y', 'Entropy Y',

```



```

211         'Mean Z', 'STD Z', 'Median Z', 'Max Z',
↳ 'Min Z', 'Energy Z', 'IQR Z', 'Entropy Z',
212         'SMA', 'Correlation X,Y', 'Correlation
↳ X,Z', 'Correlation Y,Z',
213         'Lugar_x0', 'Lugar_x1',
↳ 'Lugar_x2', 'Activity']
214     df = pd.DataFrame(result, columns = header)
215
216     return(df)
217
218
219     # In[12]:
220
221     result_train = calc_features([1,2,3,4])
222     df_train = set_df(result_train)
223     result_test = calc_features([5])
224     df_test = set_df(result_test)
225
226     print(df_train.head())
227     print(df_test.head())
228
229
230     # ## Transformação de dados não numéricos para dados
↳ numéricos
231
232     # In[13]:
233
234     def mapping(df):
235         activity_mapping = {"alta_intensidade": 0,
↳ "andar": 1, "atividades_domesticas": 2,
↳ "baixa_intensidade": 3, "comer": 4,
236                             "dormir": 5, "higiene": 6}
237
238         for key, value in activity_mapping.items():

```

```

239         df.loc[df['Activity'] == key, 'Activity'] =
↪     value
240
241     return(df)
242
243
244 # In[14]:
245
246 df_train = mapping(df_train)
247 df_test = mapping(df_test)
248
249 print(df_train.head())
250 print(df_test.head())
251
252
253 # ## Defini todas as colunas como valores numéricos
254
255 # In[15]:
256
257 for df in [df_train, df_test]:
258     for column in df:
259         if (column == 'Atividade'):
260             df[column] = df[column].astype(int)
261         else:
262             df[column] = df[column].astype(float)
263
264
265 # In[16]:
266
267 def set_x_y(df):
268     Y = df.loc[:,['Activity']]
269     X = df.loc[:,['Mean X', 'STD X', 'Median X', 'Max
↪ X', 'Min X', 'Energy X', 'IQR X', 'Entropy X',

```

```

270         'Mean Y', 'STD Y', 'Median Y', 'Max
↳ Y', 'Min Y', 'Energy Y', 'IQR Y', 'Entropy Y',
271         'Mean Z', 'STD Z', 'Median Z', 'Max
↳ Z', 'Min Z', 'Energy Z', 'IQR Z', 'Entropy Z',
272         'SMA', 'Correlation X,Y',
↳ 'Correlation X,Z', 'Correlation Y,Z',
273         'Lugar_x0', 'Lugar_x1',
↳ 'Lugar_x2']]
274
275     return(X,Y)
276
277
278 # In[17]:
279
280 X_train, Y_train = set_x_y(df_train)
281 X_test, Y_test = set_x_y(df_test)
282
283
284 # ## Cross Validation
285
286 # In[18]:
287
288 kf = ShuffleSplit(n_splits=10, train_size=None,
↳ random_state=1)
289
290
291 # ## Random Forest
292
293 # In[19]:
294
295 alg = RandomForestClassifier(random_state=1,
↳ max_depth=None, max_features=5, n_estimators=100,
↳ min_samples_split=2, min_samples_leaf=1)

```

```

296 scores = cross_val_score(alg, X_train,
    ↪ Y_train.values.ravel(), cv=kf)
297
298 print("Accuracy Random Forest: %.2f%%" %
    ↪ (scores.mean() * 100.0))
299
300
301 # ## Extra Trees
302
303 # In[20]:
304
305 alg = ExtraTreesClassifier(random_state=1,
    ↪ n_estimators=100, min_samples_split=4,
    ↪ min_samples_leaf=2)
306 scores = cross_val_score(alg, X_train,
    ↪ Y_train.values.ravel(), cv=kf)
307
308 print("Accuracy Extra Trees: %.2f%%" % (scores.mean()
    ↪ * 100.0))
309
310
311 # In[21]:
312
313 importances = alg.feature_importances_
314 std = np.std([tree.feature_importances_ for tree in
    ↪ alg.estimators_],
315              axis=0)
316 indices = np.argsort(importances)[::-1]
317
318 # Print the feature ranking
319 print("Feature ranking:")
320
321 for f in range(X_train.shape[1]):

```

```

322     print("%d. feature %d (%f)" % (f + 1, indices[f],
    ↪ importances[indices[f]]))
323
324     # Plot the feature importances of the forest
325     plt.figure()
326     plt.title("Feature importances")
327     plt.bar(range(X_train.shape[1]),
    ↪ importances[indices],
328             color="r", yerr=std[indices], align="center")
329     plt.xticks(range(X_train.shape[1]), indices)
330     plt.xlim([-1, X_train.shape[1]])
331     plt.show()
332
333
334     # ## Gradient Boosting
335
336     # In[22]:
337
338     alg = GradientBoostingClassifier(n_estimators=100,
    ↪ min_samples_split=4, min_samples_leaf=2,
    ↪ random_state=1)
339     scores = cross_val_score(alg, X_train,
    ↪ Y_train.values.ravel(), cv=kf)
340
341     print("Accuracy Gradient Boosting: %.2f%%" %
    ↪ (scores.mean() * 100.0))
342
343
344     # ## Test Data
345
346     # ## Predict
347
348     # In[23]:
349

```

```
350 alg.fit(X_train, Y_train.values.ravel())
351 predictions = alg.predict_proba(X_test)
352
353
354 # ## Confusion Matrix
355
356 # In[24]:
357
358 result = []
359
360 LABELS = activity_list
361
362 for prediction in predictions:
363     result.append(prediction.tolist().index(
364         ↪ max(prediction)))
365
366 print("Confusion Matrix:")
367 confusion_matrix =
368     ↪ metrics.confusion_matrix(Y_test.values.ravel(),
369     ↪ result)
370
371 print(confusion_matrix)
372 normalised_confusion_matrix =
373     ↪ np.array(confusion_matrix,
374     ↪ dtype=np.float32)/np.sum(confusion_matrix)*100
375
376 print("")
377 print("Confusion matrix (normalised to % of total
378     ↪ test data):")
379
380 print(normalised_confusion_matrix)
381
382
383 width = 12
384 height = 12
385 plt.figure(figsize=(width, height))
386 plt.imshow(
```

```
378     normalised_confusion_matrix,
379     interpolation='nearest',
380     cmap=plt.cm.rainbow
381 )
382 plt.title("Confusion matrix \n(normalised to % of
    ↪ total test data)")
383 plt.colorbar()
384 tick_marks = np.arange(7)
385 plt.xticks(tick_marks, LABELS, rotation=90)
386 plt.yticks(tick_marks, LABELS)
387 plt.tight_layout()
388 plt.ylabel('True label')
389 plt.xlabel('Predicted label')
390 plt.show()
391
392 print("")
393 print("Precision:
    ↪ {:.%}".format(100*metrics.precision_score(Y_test.
    ↪ values.ravel(), result, average="weighted")))
```





## **APÊNDICE C - Artigo do TCC**



## Um Modelo de Reconhecimento de Atividades Humanas em Ambientes Domiciliares Assistidos

Wagner Daufenbach do Amaral<sup>1</sup>

<sup>1</sup>Departamento de Informática e Estatística – Universidade Federal de Santa Catarina (UFSC) – Florianópolis – SC – Brazil

wagner.amaral@grad.ufsc.br

**Abstract.** *This work presents a human activity recognition model, using location and movement data, generated from an accelerometer. The activities of 5 individuals, from different age groups, were monitored, using the activities of 4 of these individuals to train the model and the activities of the remaining individual for test data. For the prediction of the activities, the algorithm Extra Trees was used, where the results of 81.16% accuracy were obtained when only movement data were used, 92.59% when using both movement and location data, and 97.56% when used movement data and synthetic location data.*

**Resumo.** *Este trabalho apresenta um modelo para o reconhecimento de atividades humanas a partir de dados de localização e movimentação, gerados a partir de um acelerômetro. Foram monitoradas as atividades de 5 indivíduos, de diferentes faixas etárias, utilizando as atividades de 4 destes indivíduos para treinar o modelo e as atividades do indivíduo restante para dados de teste. Para a predição das atividades foi utilizado o algoritmo Extra Trees, onde foram obtidos os resultados de 81,16% de precisão quando utilizados apenas dados de movimentação, 92,59% quando utilizados tanto dados de movimentação quanto localização, e 97,56% quando utilizados dados de movimentação e dados sintéticos de localização.*

### 1. Introdução

Segundo projeções do IBGE datadas de 2013, o número de idosos - pessoas com mais de 60 anos - no Brasil em 2016, representaria aproximadamente 12% da população total do país. Já para 2060, o instituto projeta que a população de idosos representará quase 34% da população do Brasil. Em números absolutos a estimativa é que o número de idosos praticamente triplique até 2060 [IBGE 2013].

Com esse grande crescimento da população de idosos, vê-se a oportunidade e a necessidade da criação de condições que garantam a eles uma vida com qualidade e independência. Com base nisso estão surgindo tecnologias que monitoram indivíduos em suas casas, os chamados Ambientes Domiciliares Assistidos. Apesar dos sistemas de detecção de atividade humana reforçarem a noção de que o principal público-alvo diz respeito à população de idosos, é importante ressaltar que, de uma forma geral, esse tipo de sistema, assim como o modelo proposto, pode ser útil para quaisquer pessoas, independentemente de sua faixa etária ou outras características que as definem.

Um Ambiente Domiciliar Assistido é composto por um conjunto heterogêneo de sensores corporais e de ambiente que geram grandes volumes de dados. Estes ambientes

usam diversas técnicas para detecção de anormalidades, porém, de uma forma geral, detectam anormalidades somente quando elas ocorrem, o que muitas vezes está ligado a um estado avançado de uma doença. Neste tipo de sistema, não é possível prever anomalias com tempo hábil para que ações preventivas seja tomadas, o que evitaria que a situação se torne crítica [Forkan et al. 2015].

Ao armazenar dados do posicionamento na residência e movimentação de um indivíduo monitorado, podemos inferir suas atividades diárias e assim entender sua rotina individual, detectando de forma mais precisa, e com antecedência, possíveis anomalias em sua saúde.

A partir disso, este trabalho de pesquisa propõe um modelo de detecção de atividade humana, baseado em dados de movimentação e localização, a partir de dispositivos de baixo custo e pequenas dimensões, focado na não intrusividade, garantindo assim uma vida com mais liberdade e qualidade para o indivíduo monitorado.

Este trabalho está organizado da seguinte forma: na seção 2 é realizada uma análise dos trabalhos correlatos; na seção 3 é apresentada e detalhada a proposta; o ambiente e os resultados obtidos são apresentados na seção 4; conclui-se o trabalho e trabalhos futuros são propostos na seção 5.

## 2. Trabalhos Correlatos

Nos últimos anos, muitos artigos passaram a abordar o tema de ambientes assistidos. Por se tratar de um conceito relativamente novo, poucos padrões são encontrados na literatura. Alguns trabalhos, como [Lee et al. 2011], [Mannini et al. 2013], utilizam apenas um único acelerômetro para o reconhecimento das atividades. Outros trabalhos, como [Dwiyantoro et al. 2016], [Murao and Terada 2016] e [Kim et al. 2015], utilizam diversos sensores para a mesma finalidade.

O uso de sensores corporais é amplamente utilizado nessa área, porém outras abordagens também são encontradas na literatura, como a utilização de imagens para o reconhecimento das atividades. Esse é o caso de trabalhos como [Maurer et al. 2006].

Para os sensores corporais, a posição do corpo onde o dispositivo será acoplado possui grande importância. Apesar de também não existir um padrão sobre onde os sensores devem ser posicionados, alguns dos lugares mais comuns são: peito, pulso, tornozelo e cintura. Em [Atallah et al. 2011] é realizado um estudo para determinar o melhor posicionamento para sensores corporais.

Em [Noor et al. 2017], a identificação de atividades humanas é feita através de um único acelerômetro triaxial, utilizando o conceito de janelas de tamanho dinâmico. O sistema de classificação consiste de três classificadores, sendo cada um deles implementado como uma árvore de decisão. Nesse trabalho, que utiliza apenas dados de movimentação, foi atingida uma precisão média de 95,4%.

Já em [Chevalier 2016], é proposto um modelo que utiliza uma *Recurrent Neural Networks* para o sistema de classificação. Para essa classificação, o modelo utiliza um conjunto público de dados de atividades humanas, disponível em [Anguita et al. 2013]. Diferentemente do modelo citado anteriormente, esse modelo utiliza dados provenientes de um smartphone, e são utilizados as informações do acelerômetro e do giroscópio deste dispositivo. A precisão média do sistema ficou em 91,55%.

Para melhor compreender o estado atual da pesquisa nessa área, realizou-se uma revisão da literatura. Foram realizadas buscas pelo termo “*activity recognition AND accelerometer*” no título de documentos de 4 bases de dados: *IEEE Xplorer*, *ProQuest*, *Scopus* e *Web of Science*. Todas as buscas foram realizadas em janeiro de 2017, sendo excluídos documentos redigidos em idioma diferente do português, inglês ou espanhol, documentos sem o texto completo disponível e documentos repetidos. Como resultado, foi encontrado um total de 253 artigos entre as 4 bases de dados, destes, 76 foram selecionados para uma análise mais detalhada.

### 2.1. Comparativo das Abordagens

A Tabela 1 apresenta uma comparação entre as abordagens utilizadas em alguns dos trabalhos selecionados durante a revisão da literatura.

**Tabela 1. Comparativo de Trabalhos de Pesquisa**

Referência	Sensor	Localização do sensor	Método de classificação
[Mannini et al. 2013]	Acelerômetro	Pulso ou Tornozelo	Support Vector Machine
[Dwiyantoro et al. 2016]	Acelerômetro e Sensor de gravidade (smartphone)	Bolso frontal da calça	Dynamic Time Warping e K-Nearest Neighbors
[Muraó and Terada 2016]	Múltiplos acelerômetros	Ambos pulsos e tornozelos e quadril	Dynamic Time Warping e Support Vector Machine
[Kim et al. 2015]	Acelerômetro e Giroscópio (smartphone)	Cintura	Hidden Markov Model


### 3. Proposta

Com o crescimento da expectativa de vida, soluções focadas para Ambientes Domiciliares Assistidos surgem com o objetivo de melhorar a qualidade de vida e garantir independência para idosos.

Este trabalho propõe um modelo de reconhecimento de atividade humana por indivíduos monitorados dentro de suas casas. Os dados a serem analisados para esta predição são de posicionamento e de movimentação.

A Figura 1 mostra uma visão geral do modelo proposto. A figura representa desde a entrada de dados, que são capturados a partir de sensores, até a predição da atividade realizada pelo indivíduo monitorado.

O principal objetivo deste trabalho é propor um modelo capaz de inferir com precisão qual atividade o indivíduo monitorado está realizando a partir dos dados de localização e movimentação deste indivíduo.



**Figura 1. Visão geral do modelo HARA**

Fonte: elaborado pelo autor.

### 3.1. Obtenção dos Dados

Sabendo que as atividades de um indivíduo estão fortemente ligadas a sua localização dentro de casa [Zhu and Sheng 2011], o modelo proposto incorpora em seu sistema a identificação da localização *indoor* do indivíduo monitorado.

A movimentação do indivíduo é identificada a partir de um único acelerômetro acoplado ao corpo do indivíduo monitorado. Segundo [Atallah et al. 2011] os melhores resultados para identificação de atividades domésticas foram encontrados quando o sensor corporal foi acoplado a cintura ou ao pulso do indivíduo monitorado. Visando a menor intrusividade possível, optou-se por utilizar o sensor no pulso do indivíduo nesta pesquisa. Para os dados de localização do indivíduo dentro do ambiente dispositivos *Bluetooth* estarão espalhados pelo ambiente para mapear a intensidade do sinal enviado pelo sensor corporal.

#### 3.1.1. Movimentação

Para obter a movimentação do indivíduo, o mesmo carregará consigo um sensor corporal que será composto por um *Tinyduino*, um *shield* BLE para a comunicação entre o sensor e o sistema computacional, e um *shield* de acelerômetro. A placa principal e os *shields* podem ser vistos na Figura 2. As dimensões do sensor montado são 20mm x 20mm x 16.8mm.



**Figura 2. Tinyduino, shield BLE e shield de acelerômetro**

Fonte: foto tirada pelo autor.

### 3.1.2. Localização

Para a identificação da localização de um indivíduo, dispositivos *Bluetooth* estarão espalhados pelo ambiente. Estes dispositivos ficarão responsáveis por verificar a intensidade de sinal do *shield* BLE carregado pelo indivíduo no sensor corporal. A localização *indoor* do indivíduo monitorado será definida de acordo com a intensidade do sinal medido pelos dispositivos *Bluetooth*.

Nesta etapa será necessário treinar o modelo para reconhecer os ambientes da casa, andando com o sensor corporal pela casa e informando manualmente em qual ambiente o indivíduo se encontra.

O processo de identificação das localizações é descrito abaixo:

1. Cada um dos dispositivos *Bluetooth* persistirá os dados referente a intensidade do sinal do sensor corporal em um banco de dados MySQL a cada segundo;
2. O sistema computacional será responsável por ler os últimos 12 dados persistidos (teoricamente 3 de cada um dos dispositivos *Bluetooth*), e calcular a intensidade média de cada um dos dispositivos;
3. A intensidade média de cada um dos dispositivos é utilizada como característica para a predição da localização;
4. Será utilizado o algoritmo K-NN para predição da localização;
5. A predição será persistida no banco de dados.

### 3.2. Reconhecimento das Atividades

Para o reconhecimento das atividades, foi selecionado o algoritmo *Extra Trees* implementado pela Scikit-learn [Pedregosa et al. 2011]. Serão utilizados 80% dos dados disponíveis para treino e 20% para teste. Para avaliar o modelo, será realizado uma validação cruzada (*k-fold*) nos dados de treino, com 10 subconjuntos.

Para os dados do acelerômetro, é definido uma janela de 5 segundos, com sobreposição de 3 segundo, com exceção da última janela, que se adequará ao tempo disponível. Por exemplo, se tivermos dados referentes a 10 segundos de monitoramento do acelerômetro, teremos as seguintes janelas: [0s-5s], [2s-7s], [4s-9s], [5s-10s].

Devido ao algoritmo utilizado trabalhar apenas com dados numéricos, é necessário converter as localizações para este tipo de dado. A codificação binária foi escolhida para esta conversão, como temos 7 ambientes na casa, precisamos de 3 novas características.

#### 3.2.1. Seleção de Características

A seleção das características para a uso no algoritmo de reconhecimento de atividades baseou-se na proposta de [Chevalier 2016]. Cada uma das características é calculada levando-se em consideração os dados referente a sinais de 5 segundos de duração do acelerômetro, com exceção das características de localização. A seguir são listadas as características selecionadas:

- **Média [X, Y, Z]** - média dos valores de cada eixo;
- **Desvio Padrão [X, Y, Z]** - desvio padrão dos valores de cada eixo;

- **Mediana [X, Y, Z]** - mediana dos valores de cada eixo;
- **Valor Máximo [X, Y, Z]** - maior valor de cada eixo;
- **Valor Mínimo [X, Y, Z]** - menor valor de cada eixo;
- **Energia [X, Y, Z]** - dada pela fórmula  $\frac{\sum_{i=1}^n (k_i^2)}{n}$  para os valores de cada eixo, onde  $n$  é a quantidade de valores;
- **Amplitude Interquartil [X, Y, Z]** - definida pela diferença entre o terceiro e o primeiro quartil dos valores de cada eixo;
- **Entropia [X, Y, Z]** - dado pela fórmula  $-\sum_{i=1}^n (k_i * \log(k_i))$  para os valores de cada eixo, onde  $n$  é a quantidade de valores.
- **Signal magnitude area (X, Y, Z)** - dado pela fórmula  $\frac{\sum_{i=1}^n (|x_i|+|y_i|+|z_i|)}{n}$ , onde  $n$  é a quantidade de valores em um eixo;
- **Correlação [(X,Y), (X,Z), (Y,Z)]** - coeficiente de correlação entre os dados dos eixos, dois a dois;
- **Lugar [x0, x1, x2]** - codificação binária referente a localização *indoor*.

#### 4. Ambientes e Resultados

Nesta seção, são apresentados os resultados experimentais do modelo proposto. Para esta etapa, foram monitorados 5 indivíduos, 2 destes com idades entre 20 e 30 anos, 1 com idade entre 30 e 40 anos e 2 com mais de 60 anos. Os dados de um dos indivíduos da faixa entre 20 e 30 anos foram utilizados como dados de teste e os dados dos demais indivíduos foram utilizados como dados de treino. Com os dados desse monitoramento foram criados dois cenários distintos. Primeiro foram utilizados apenas os dados de movimentação para o reconhecimento das atividades, em seguida além dos dados de movimentação também são utilizados os dados de localização *indoor*.

O ambiente no qual os experimentos foram conduzidos possui uma área de aproximadamente 67m<sup>2</sup>, dividido nos seguintes cômodos: sala, corredor, escritório, cozinha, área de serviço, banheiro e quarto. O sistema computacional (*Raspberry Pi 3 Model B*) foi posicionado na Cozinha, enquanto os dispositivos *Bluetooth* (três notebooks), foram posicionados no Escritório, Quarto e Sala.

A fim de gerar dados de uma grande variedade de atividades e localidades, aproximando-se da rotina real de um indivíduo, foi criado um roteiro de atividades. Atividades como andar e varrer, por exemplo, podem ser executadas em qualquer ambiente da casa, enquanto escovar os dentes é uma atividade exclusiva do banheiro.

As atividades foram divididas em sete classes: alta intensidade, andar, atividade doméstica, baixa intensidade, comer, dormir e higiene pessoal. Para cada classe de atividade definiu-se o tempo de 2 minutos, e este tempo foi dividido de forma igualitária entre as atividades desta classe. As classes que possuem menos atividades, dispõem de mais tempo para cada atividade, como é o caso da classe Alta Intensidade, que por possuir apenas uma atividade, dispõe de 120 segundos para a atividade. Classes que possuem mais atividades, por outro lado, dispõem de menos tempo para cada atividade, como é o caso da classe Atividade Doméstica, que por possuir 11 atividades, dispõe de uma média de 11 segundos para cada atividade.

##### 4.1. Cenários

O cenário I apresenta os resultados para os testes onde foram utilizados apenas dados de movimentação para o reconhecimento de atividade humana. O cenário II apresenta os



resultados para os testes onde foram utilizados dados de movimentação e localização. O cenário II foi realizado de duas formas diferentes, em II(a) são utilizados os dados de localização provenientes do modelo proposto, em II(b) são utilizados dados sintéticos de localização, considerando uma precisão de 100%, ou seja, todas as localizações estão corretas. Essa decisão foi tomada uma vez que foi identificada uma baixa precisão nos dados de localização *indoor* para ambientes que não possuíam dispositivos *Bluetooth* (Corredor, Banheiro e Área de Serviço). Ambientes com dispositivos *Bluetooth* alcançaram uma precisão próxima de 95% enquanto ambientes sem dispositivos *Bluetooth* apresentaram precisão próxima a 30%.

#### 4.2. Validação Cruzada

Foram executados testes com 3 diferentes algoritmos: *Extra Trees*, *Gradient Boosting* e *Random Forest*. A tabela 2 apresenta um comparativo da precisão do modelo para os dados de treino utilizando os algoritmos citados.

Tabela 2. Comparativo Validação Cruzada

Algoritmo	Cenário I	Cenário II(a)	Cenário II(b)
<i>Extra Trees</i>	95,32%	94,68%	99,35%
<i>Gradient Boosting</i>	94,94%	95,26%	98,05%
<i>Random Forest</i>	94,68%	95,58%	98,77%

#### 4.3. Importância das Características

Durante a execução dos testes experimentais observou-se que características mais complexas (Amplitude Interquartil, Entropia, Signal Magnitude Area e Correlação de sinais), são as que apresentam menor importância para o modelo, enquanto características mais simples como valor máximo, e valor mínimo possuem um peso maior para o processo de seleção.

Nos cenários II(a) e II(b), onde foram incorporados dados de localização, observa-se que as características relacionadas a localização tomaram papel de destaque, possuindo um grande peso no processo de seleção. No cenário II(b) onde todas as localizações estavam corretas estas características possuem um peso, em média, 3 vezes maior do que as demais características.

#### 4.4. Precisão do Modelo

A tabela 3 apresenta um comparativo da precisão do modelo para os dados de teste.

Tabela 3. Precisão dos cenários

Cenário	Precisão
I	81,16%
II(a)	92,59%
II(b)	97,56%

Apesar da alta precisão do modelo na validação cruzada do cenário I (95,32%), ocorreu uma queda considerável quando o modelo é aplicado para dados de teste, obtendo

uma precisão de 81,16%. Um ponto interessante a ser observado diz respeito a classe com maior índice de erro - higiene pessoal -, ser uma das que está mais fortemente ligada a uma localização dentro de casa - banheiro.

Com a adição da localização nos cenários II(a) e II(b), observou-se uma diminuição considerável nos erros de classificação da classe higiene pessoal, chegando a 0% no cenário II(b).

A figura 3 apresenta as matrizes de confusão dos cenários I, II(a) e II(b).




Figura 3. Matriz de confusão dos cenários I, II(a) e II(b)

Fonte: elaborado pelo autor.

## 5. Conclusões e Trabalhos Futuros

Ao longo deste trabalho ficou clara a falta de padrão existente na literatura referente a este contexto e a vasta gama de abordagens utilizadas. Para este trabalho, decidiu-se utilizar uma abordagem onde o indivíduo monitorado carrega apenas um único sensor corporal, e dados de localização e movimentação são enviados para o sistema computacional para a predição das atividades.

O modelo mostrou-se eficaz para o reconhecimento de atividades humanas para os dados de teste, apresentando precisões de 81,16% quando utilizados apenas dados de movimentação, 92,59% quando utilizados dados de movimentação e localização e 97,56% quando utilizados dados de movimentação e dados sintéticos de localização.

Durante os testes foram identificados alguns problemas de comunicação *Bluetooth*, principalmente para o sistema de localização *indoor*, o que levou a uma baixa precisão para este sistema em ambientes onde não haviam dispositivos *Bluetooth* (Corredor, Banheiro e Área de Serviço). Para lidar com este problema, utilizando a mesma abordagem, seria necessário a instalação de dispositivos *Bluetooth* em todos os ambientes monitorados, o que seria inviável para o público em geral. Mesmo com o problema da comunicação a importância da localização para o reconhecimento de atividade humana foi comprovado ao utilizarmos dados sintéticos de localização.

O posicionamento dos dispositivos *Bluetooth* também foi um ponto chave para o sucesso da pesquisa. Foi necessário testar diversas disposições dos dispositivos para se chegar a resultados satisfatórios. Obstruções no caminho entre o dispositivo *Bluetooth* e

o sensor corporal, por menor que sejam, podem ter um grande impacto nas medições de intensidade de sinal.

O uso do acelerômetro como sensor principal para a identificação de atividades deu-se principalmente por seu baixo consumo energético e suas pequenas dimensões, o que favorece a não intrusividade, garantindo uma vida com qualidade e independência para os indivíduos monitorados.

Com os resultados da pesquisa, são sugeridas abaixo algumas melhorias que poderão ser tratadas em trabalhos futuros:

- Estudar outras tecnologias de comunicação a fim de diminuir o impacto das falhas de comunicação dos dispositivos *Bluetooth*;
- Identificar outras técnicas de localização *indoor* que apresentem resultados mais consistentes. São recomendadas especificamente técnicas baseadas em RFID ou intensidade do sinal WIFI como possíveis soluções;
- Aplicação de um filtro de Qualidade de Contexto para definir quais dados devem ser armazenados ou descartados;
- Implementar um sistema capaz de gerar a rotina do indivíduo monitorado a partir das suas atividades e gerar alertas caso esta rotina seja quebrada.

## Referências

- Anguita, D., Ghio, A., Oneto, L., Parra, X., and Reyes-Ortiz, J. L. (2013). A public domain dataset for human activity recognition using smartphones. In *21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2013*.
- Atallah, L., Lo, B., King, R., and Yang, G. Z. (2011). Sensor positioning for activity recognition using wearable accelerometers. *IEEE Transactions on Biomedical Circuits and Systems*, 5(4):320–329.
- Chevalier, G. (2016). Lstms for human activity recognition. <<https://github.com/guillaume-chevalier/LSTM-Human-Activity-Recognition>>. Acesso em: 13/06/2017.
- Dwiyantoro, A. P. J., Nugraha, I. G. D., and Choi, D. (2016). A simple hierarchical activity recognition system using a gravity sensor and accelerometer on a smartphone. *International Journal of Technology*, 7(5).
- Forkan, A. R. M., Khalil, I., Tari, Z., Foufou, S., and Bouras, A. (2015). A context-aware approach for long-term behavioural change detection and abnormality prediction in ambient assisted living. *Pattern Recognition*, 48(3):628–641.
- IBGE (2013). Projeção da população do brasil por sexo e idade 2000-2060. Revisão 2013.
- Kim, Y. J., Kang, B. N., and Kim, D. (2015). Hidden markov model ensemble for activity recognition using tri-axis accelerometer. In *2015 IEEE International Conference on Systems, Man, and Cybernetics*, pages 3036–3041.
- Lee, M.-W., Khan, A. M., and Kim, T.-S. (2011). A single tri-axial accelerometer-based real-time personal life log system capable of human activity recognition and exercise information generation. *Personal and Ubiquitous Computing*, 15(8):887–898.

- Mannini, A., Intille, S. S., Rosenberger, M., Sabatini, A. M., and Haskell, W. (2013). Activity recognition using a single accelerometer placed at the wrist or ankle. *Medicine and Science in Sports and Exercise*, 45(11):2193–2203.
- Maurer, U., Smailagic, A., Siewiorek, D. P., and Deisher, M. (2006). Activity recognition and monitoring using multiple sensors on different body positions. In *Proceedings of the International Workshop on Wearable and Implantable Body Sensor Networks, BSN '06*, pages 113–116, Washington, DC, EUA. IEEE Computer Society.
- Murao, K. and Terada, T. (2016). A combined-activity recognition method with accelerometers. *Journal of Information Processing*, 24(3):512–521.
- Noor, M. H. M., Salcic, Z., and Wang, K. I.-K. (2017). Adaptive sliding window segmentation for physical activity recognition using a single tri-axial accelerometer. *Pervasive and Mobile Computing*, 38(Part 1):41 – 59.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Zhu, C. and Sheng, W. (2011). Motion- and location-based online human daily activity recognition. *Pervasive Mob. Comput.*, 7(2):256–269.