

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MEZQUITA FILHO”  
FACULDADE DE ENGENHARIA  
CAMPUS DE ILHA SOLTEIRA**

**MELISA DE JESÚS BARRERA DURANGO**

**SIRAH: SISTEMA DE RECONHECIMENTO DE ATIVIDADES HUMANAS E  
AVALIAÇÃO DO EQUILIBRIO POSTURAL**

**Ilha Solteira  
2017**

**MELISA DE JESÚS BARRERA DURANGO**

**SIRAH: SISTEMA DE RECONHECIMENTO DE ATIVIDADES HUMANAS E  
AVALIAÇÃO DO EQUILIBRIO POSTURAL**

Tese apresentada à Faculdade de Engenharia do Campus de Ilha Solteira – UNESP como parte dos requisitos para obtenção de Doutor em Engenharia. Área de concentração: Automação.

Prof. Dr. Alexandre César Rodrigues da Silva  
**Orientador**

Ilha Solteira

2017

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

Barrera Durango, Melisa de Jesús.

B272s      SIRAH: sistema de reconhecimento de atividades humanas e avaliação do equilíbrio postural / Melisa de Jesús Barrera Durango. -- Ilha Solteira: [s.n.], 2017

139 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2017

Orientador: Alexandre César Rodrigues da Silva

Inclui bibliografia

1. Inteligência ambiental. 2. Ambientes inteligentes. 3. Internet das coisas. 4. Reconhecimento de atividades humanas. 5. Sensores. 6. Redes neurais artificiais.

**CERTIFICADO DE APROVAÇÃO**

TÍTULO DA TESE: SIRAH: Sistema de Reconhecimento de Atividades Humanas e Avaliações do Equilíbrio Postural


**AUTORA: MELISA DE JESÚS BARRERA DURANGO**

**ORIENTADOR: ALEXANDRE CESAR RODRIGUES DA SILVA**


Aprovada como parte das exigências para obtenção do Título de Doutora em ENGENHARIA ELÉTRICA, área: AUTOMAÇÃO pela Comissão Examinadora:

  
Prof. Dr. ALEXANDRE CESAR RODRIGUES DA SILVA  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

  
Prof. Dr. APARECIDO AUGUSTO DE CARVALHO  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

  
Prof. Dr. CARLOS ROBERTO MINUSSI  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

  
Profa. Dra. DANIELA GODOI JACOMASSI  
Departamento de Educação Física e Motricidade Humana / Universidade Federal de São Carlos

  
Prof. Dr. EDSON ANTONIO BATISTA  
Faculdade de Engenharias, Arquitetura e Urbanismo / Universidade Federal de Mato Grosso do Sul

Ilha Solteira, 09 de junho de 2017

## **DEDICATÓRIA**

Dedico esta tese os meus pais Carmiña e José Antonio, que me educaram e deram o melhor exemplo de vida.

Ao meu esposo Miller e meu filho Elías, minha amada família, meu motor.

Sem o apoio e amor de vocês, este trabalho não teria sido realizado.

## **AGRADECIMENTOS**

Agradeço a Deus por minha vida e todas as bênçãos que me deu e cada dia continuo recebendo.

Aos meus pais Carmiña e José Antonio, pelo imenso amor, que mesmo longe me fortalece em todo momento. Obrigada por acreditar em mim e me apoiar nesta caminhada e por me ajudar a não desistir dos meus sonhos.

Ao meu esposo Miller, pelo amor, paciência e dedicação, tanto nos bons momentos quanto nos tempos de crise e estresse. Você é meu complemento e como já te disse inúmeras vezes, sem você eu não estaria aqui.

Ao meu amado filho Elías José. Há pouco chegaste na minha vida, mas a mudaste completamente. Obrigada filho por me ensinar o que é ser mãe e a sentir um amor tão grande que não cabe no meu peito. Este logro é para ti e por ti.

Ao querido orientador professor doutor Alexandre, pelo apoio incondicional, por sempre estar aí quando mais precisava e não me deixar desistir quando pensei que não conseguiria. Obrigada por seus ensinamentos, tanto teóricos quanto pessoais durante o doutorado.

Aos meus colegas Caroline Meireles e Fabian Castro do Laboratório de Instrumentação Eletrônica e Engenharia Biomédica, e Willian Ferreira do Laboratório de Processamento De Sinais e Sistemas Digitais, por trabalhar comigo e me ajudar a desenvolver esta pesquisa.

À professora Daniela Godoi, da Universidade Federal de São Carlos, pelas ideias e orientações que generosamente me deu e que me ajudaram na finalização desta pesquisa.

A minha querida Universidad de Antioquia por me permitir viver esta experiência de crescimento profissional e espiritual. Estou ansiosa por voltar a minha Alma Mater.

## RESUMO

O reconhecimento de atividades humanas abrange diversas técnicas de classificação que permitem identificar padrões específicos do comportamento humano no momento da ocorrência. A identificação é realizada analisando dados gerados por diversos sensores corporais, entre os quais destaca-se o acelerômetro, pois responde tanto à frequência como à intensidade dos movimentos. A identificação de atividades é uma área bastante explorada. Porém, existem desafios que necessitam ser superados, podendo-se mencionar a necessidade de sistemas leves, de fácil uso e aceitação por parte dos usuários e que cumpram com requerimentos de consumo de energia e de processamento de grandes quantidades de dados. Neste trabalho apresenta-se o desenvolvimento do Sistema de Reconhecimento de atividades Humanas e Avaliação do Equilíbrio Postural, denominado SIRAH. O sistema está baseado no uso de um acelerômetro localizado na cintura do usuário. As duas fases do reconhecimento de atividades são apresentadas, fase *Offline* e fase *Online*. A fase *Offline* trata do treinamento de uma rede neural artificial do tipo perceptron de três camadas. No treinamento foram avaliados três estudos de caso com conjuntos de atributos diferentes, visando medir o desempenho do classificador na diferenciação de 3 posturas e 4 atividades. No primeiro caso o treinamento foi realizado com 15 atributos, gerados no domínio do tempo, com os que a rede neural artificial alcançou uma precisão de 94,40%. No segundo caso foram gerados 34 atributos tanto no domínio do tempo quanto da frequência. Uma vez treinada a rede neural artificial, esta classificou corretamente as posturas e atividades em 94,35% das vezes. No terceiro caso aplicou-se o método de seleção automática PCA (Principal Component Analysis) no conjunto de 34 atributos. Com 20 componentes principais a rede neural artificial teve uma precisão de 95,55%. Na fase *Online* foi implementado no sistema SIRAH o modelo obtido no treinamento com o primeiro estudo de caso, com o objetivo de classificar dados novos do sensor em tempo real. Estes atributos são gerados exclusivamente no domínio do tempo, evitando a implementação da Transformada de Fourier no sistema, que aumentaria a complexidade computacional e o tempo de execução do algoritmo. O sistema SIRAH envia ao computador a atividade ou postura classificada, limitando desta forma a quantidade de informação transmitida na rede local. O sistema SIRAH também calcula a raiz do valor quadrático médio da aceleração horizontal e os deslocamentos nos eixos ântero-posterior e médio-lateral do centro de massa do corpo, indicadores da oscilação corporal, parâmetros sugeridos como medida do equilíbrio na postura ereta semi-estática. Para validar esta funcionalidade foram realizados testes que alteram o sistema de controle postural, usados para avaliar o equilíbrio. Os resultados dos testes mostraram que o acelerômetro consegue diferenciar estas condições, concluindo-se que esta funcionalidade torna ao sistema SIRAH uma ferramenta válida na avaliação da oscilação corporal contínua, que pode ser usada em ambientes externos a clínicas e laboratórios especializados. SIRAH, com suas duas funcionalidades, é um sistema confortável e de fácil uso, pois sua localização não atrapalha os movimentos dos usuários.

**Palavras-chave:** Inteligência ambiental. Ambientes inteligentes. Internet das coisas. Reconhecimento de atividades humanas. Sensores. Sensores corporais. Acelerômetro. Classificação em tempo real. Redes neurais artificiais. Oscilação corporal. Baropodômetro.

## ABSTRACT

Human activity recognition encompasses varying classification techniques that identify of specific patterns of human behavior at the time of their occurrence. Identification is achieved by analyzing data generated by several body sensors, in particular the accelerometer, as it responds to both the frequency and the intensity of the movements. Human activity recognition is a well-explored area. However, there are challenges that need to be overcome, such as the need for light systems that are easy to use, user-friendly, that meet energy consumption requirements and can process large amounts of data. In this research is presented the development of the of Human Activity Recognition and Balance Assessment System, denominated SIRAH. The system is based on an accelerometer used in the user's waist. Two phases of activity recognition are presented, *offline* phase and *online* phase. The *offline* phase deals with the training of an Artificial Neural Network. In the training, three case studies with different sets of features were evaluated in order to measure the performance of the classifier on the classification of 3 postures and 4 activities. In the first case, the Artificial Neural Network achieved an accuracy of 94.40% using 15 features generated in the time domain. In the second case, 34 features were generated in both time and frequency domains. Once the Artificial Neural Network was trained, it correctly classified the postures and activities in 94.35% of the instances. In the third case, the PCA (Principal Component Analysis) automatic selection method was applied to the second case study. With 20 components, the Artificial Neural Network had an accuracy of 95.55%. In the *online* phase, the model obtained training for the first case study was implemented in the SIRAH system to classify new sensor data in real time. These attributes are generated exclusively in the time domain and so the need to implement the Fourier Transform in the system is avoided. This would increase the computational complexity and the execution time of the algorithm. The SIRAH system only sends the classified activity or posture to the computer, thereby limiting the amount of information transmitted in the local network. The SIRAH system also calculates root mean square value for horizontal accelerations and the displacements on the anteroposterior and mediolateral axes of the body mass center, body sway indicators, suggested parameters for body sway measurement in quiet standing. To validate this functionality were performed tests that alter the balance control system, used to evaluate a person's balance. The results of the tests showed that the accelerometer can differentiate these conditions, concluding that the SIRAH system is a valid tool in the assessment of continuous body sway, which can be used in environments outside specialized clinics and laboratories. SIRAH, with its two functionalities, is a comfortable and easy to use system, because its location does not disturb the movements of the users.

**Key words** - Ambient intelligence: Smart environments. Internet of things. Human activity recognition. Sensors. Wearable sensor. Accelerometer. Online classification. Real-time classification. Artificial neural network. Principal component analysis. Body sway. Baropodometer.

## LISTA DE FIGURAS

Figura 1 - Diferentes partes do corpo as que são dirigidas as aplicações da Aml e IoT. ....	22
Figura 2 - Componentes e caraterísticas das cidades inteligentes. ....	29
Figura 3 - Enfoques no estudo do uso de acelerômetros no HAR. ....	37
Figura 4: Sistema massa mola. ....	45
Figura 5 - eixos do acelerômetro. ....	46
Figura 6 - Modelo físico simplificado do transdutor. ....	56
Figura 7 - Sistema SIRAH desenvolvido e o posicionamento no indivíduo. ....	57
Figura 8 - Hardware do SIRAH. ....	57
Figura 9 - Eixos do acelerômetro no corpo do usuário. ....	58
Figura 10 - Processos da fase <i>Offline</i> do SIRAH. ....	60
Figura 11 - Acelerações geradas na postura ereta. ....	62
Figura 12 – Acelerações geradas na postura sentada. ....	63
Figura 13 - Acelerações geradas na postura deitada. ....	63
Figura 14 - Acelerações geradas na atividade caminhar. ....	64
Figura 15 - Acelerações geradas na atividade correr. ....	65
Figura 16 - Acelerações geradas nas atividades levantar e sentar. ....	65
Figura 17 - Multiplicação dos eixos Y e Z. ....	66
Figura 18 - Picos identificados e atividades levantar e sentar separadas. ....	67
Figura 19 - Filtro passa-baixas, postura ereta. ....	68
Figura 20 - Filtro passa-baixas, atividade correr. ....	68
Figura 21 - Filtro passa-altas, postura ereta. ....	69
Figura 22 - Postura sentada segmentada com janela de 2s. ....	71
Figura 23 - Atividade correr segmentada com janela de 2s. ....	71
Figura 24 - Atividades levantar-se e sentar-se segmentadas com janelas de 2s. ....	72
Figura 25 - Modelo básico do neurônio. ....	78
Figura 26 - RNA perceptron multicamadas. ....	80
Figura 27 - RNA do sistema SIRAH. ....	82
Figura 28 - Atividade sentar-se. ....	85

Figura 29 - Atividade levantar-se.....	85
Figura 30 - Precisão PCA.....	87
Figura 31 - Média eixo Y nas atividades sentar-se e levantar-se.....	89
Figura 32 - Média eixo Y na atividade sentar-se e a postura ereta .....	90
Figura 33 – Transições entre as posturas sentada e ereta .....	91
Figura 34 – Fluxograma do algoritmo implementado em Matlab.....	92
Figura 35 – Fase <i>Offline</i> versus Fase <i>Online</i> . .....	95
Figura 36 - Fluxograma da classificação <i>Online</i> .....	96
Figura 37- Representação dos eixos ântero-posterior e médiolateral no corpo humano, plataforma de força e a trajetória do CP.....	101
Figura 38-Relação entre a aceleração medida em um eixo inclinado com um ângulo $\alpha$ e a aceleração horizontal real.....	105
Figura 39- Acelerações medida e real no eixo ântero-posterior AP, obtidas com o MMA7455L.....	106
Figura 40- Acelerações medida e real no eixo ântero-posterior AP, obtidas com o MPU-6050. ....	107
Figura 41- Coordenadas da trajetória da projeção do vetor de aceleração no solo	108
Figura 42- Trajetória da oscilação corporal e cálculo dos parâmetros .....	110
Figura 43- Pêndulo simples.....	110
Figura 44 - Ângulos do método .....	111
Figura 45 - Ângulos calculados pelo método com o acelerômetro da posição horizontal.....	112
Figura 46- Ângulos calculados no experimento realizado com o pêndulo.....	112
Figura 47- Deslocamentos calculados no experimento realizado com o pêndulo..	113
Figura 48 - Acelerações reais nos eixos ML e AP, na condição OA. ....	114
Figura 49 - Acelerações reais nos eixos ML e AP, na condição OF.....	115
Figura 50 – Deslocamentos e parâmetros calculados nas condições OA e OF.....	116
Figura 51- Coleta de dados com o acelerômetro e baropodômetro simultaneamente.....	117
Figura 52 - Acelerações e valores RMS do eixo ML nas condições OA, OF e 1P.	118
Figura 53 - Acelerações e valores RMS do eixo AP nas condições OA, OF e 1P.	119

Figura 54 – Deslocamentos e parâmetros nas condições OA, OF e 1P. ....	119
Figura 55 - SIRAH sistema de reconhecimento de atividades e avaliação do equilíbrio.....	121

## LISTA DE TABELAS

Tabela 1 - Exemplo de conjunto usado no primeiro estudo de caso .....	78
Tabela 2 - Exemplos de treinamento do primeiro estudo de caso.....	82
Tabela 3 - Precisão dos estudos de caso realizados .....	88
Tabela 4 - Condições avaliadas com as acelerações horizontais. ....	103
Tabela 5 - Parâmetros calculados com o baropodômetro.....	120

## LISTA DE QUADROS

Quadro 1 - Funcionalidades oferecidas por alguns <i>smart wearables</i> .....	23
Quadro 2 - Tipos de atividades reconhecidas por sistemas HAR. ....	32
Quadro 3 - Sensores fixos com possíveis aplicações no HAR.....	33
Quadro 4 - Diferentes atividades e suas acelerações, dependendo da localização do acelerômetro no corpo humano.....	47
Quadro 5 - Atributos extraídos no domínio do tempo.....	73
Quadro 6 - Atributos extraídos no domínio da frequência .....	74
Quadro 7- Estudos de caso realizados com diferentes atributos .....	77

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO GERAL</b> .....	<b>16</b>
1.1	OBJETIVOS DA TESE .....	18
1.1.1	<i>Objetivo geral</i> .....	18
1.1.2	<i>Objetivos específicos</i> .....	18
1.2	INTELIGÊNCIA AMBIENTAL E A INTERNET DAS COISAS .....	19
1.3	APLICAÇÕES DA INTELIGÊNCIA AMBIENTAL E A INTERNET DAS COISAS.....	22
1.3.1	<i>Smart wearables ou wearable sensors</i> .....	22
1.3.2	<i>Casas inteligentes</i> .....	24
1.3.3	<i>Cidades inteligentes</i> .....	27
<b>2</b>	<b>ESTADO DA ARTE: RECONHECIMENTO DE ATIVIDADES</b> .....	<b>31</b>
2.1	ATIVIDADES A SEREM IDENTIFICADAS .....	31
2.2	SENSORES APLICADOS NO HAR .....	32
2.3	RECONHECIMENTO DE ATIVIDADES COM SENSORES CORPORAIS	35
2.3.1	<i>Reconhecimento de atividades com acelerômetros, magnetômetros e/ou giroscópios</i> .....	36
2.3.2	<i>Reconhecimento de atividades com câmeras e outros sensores</i> .....	41
2.3.3	<i>Reconhecimento de atividades com sistemas híbridos</i> .....	42
<b>3</b>	<b>RECONHECIMENTO DE ATIVIDADES COM ACELERÔMETRO</b> .....	<b>44</b>
3.1	COLETA DE DADOS.....	45
3.1.1	<i>Caraterísticas do acelerômetro</i> .....	45
3.2	FILTRAGEM DOS DADOS.....	48
3.3	SEGMENTAÇÃO DE DADOS .....	49
3.3.1	<i>Janela deslizante</i> .....	49
3.3.2	<i>Janela definida por eventos</i> .....	49
3.3.3	<i>Janela definida por atividades</i> .....	50
3.3.4	<i>Janela definida por outros sensores e informação contextual</i> .....	50
3.4	GERAÇÃO DE ATRIBUTOS .....	50
3.4.1	<i>Atributos no domínio do tempo</i> .....	51
3.4.2	<i>Atributos no domínio da frequência</i> .....	51

3.4.3	<i>Atributos heurísticos</i> .....	51
3.4.4	<i>Análise de Wavelet</i> .....	52
3.5	NORMALIZAÇÃO .....	53
3.6	SELEÇÃO DE ATRIBUTOS .....	53
<b>4</b>	<b>SIRAH: SISTEMA DE RECONHECIMENTO DE ATIVIDADES HUMANAS</b> .....	<b>55</b>
4.1	ATIVIDADES A SEREM IDENTIFICADAS .....	55
4.2	TIPO DE SENSOR .....	55
4.3	LOCALIZAÇÃO DO SENSOR.....	56
4.4	ELEMENTOS DE HARDWARE E SOFTWARE .....	57
4.5	FASE OFFLINE .....	59
4.5.1	<i>Coleta de dados com o sensor MMA7455L</i> .....	60
4.5.2	<i>Filtro</i> .....	67
4.5.3	<i>Segmentação</i> .....	69
4.5.4	<i>Geração de atributos</i> .....	72
4.5.5	<i>Normalização</i> .....	75
4.5.6	<i>Seleção dos atributos</i> .....	75
4.5.7	<i>Treinamento da rede neural artificial</i> .....	78
4.5.8	<i>Avaliação da RNA</i> .....	84
4.5.9	<i>Implementação em Matlab da fase Offline</i> .....	91
4.6	FASE ONLINE .....	94
4.7	DESENVOLVIMENTO DO SISTEMA EM UM MICROCONTROLADOR ATMEGA2560 .....	95
<b>5</b>	<b>SIRAH: AVALIAÇÃO DO EQUILIBRIO POSTURAL</b> .....	<b>100</b>
5.1	ANÁLISE DAS ACELERAÇÕES DO CENTRO DE MASSA .....	103
5.2	ANÁLISE DO DESLOCAMENTO DO CENTRO DE MASSA .....	107
5.3	AVALIAÇÃO DOS MÉTODOS .....	114
5.4	SIRAH: ABORDAGEM INTEGRADA.....	120
<b>6</b>	<b>CONCLUSÃO E TRABALHO FUTURO</b> .....	<b>123</b>
	<b>REFERÊNCIAS</b> .....	<b>128</b>

## 1 INTRODUÇÃO GERAL

A Inteligência ambiental é um conceito que se refere a espaços melhorados com sensores, atuadores e *software*, que ajudam as pessoas no desenvolvimento das tarefas diárias. A evolução natural da Inteligência Ambiental é a Internet das Coisas, paradigma segundo o qual os dispositivos incluídos na Inteligência Ambiental estão conectados à Internet, compartilhando dados e cooperando entre eles para oferecer serviços de valor agregado. Estes conceitos estão sendo estudados há vários anos, mas sua implementação ainda está em andamento.

As aplicações abrangidas na Inteligência Ambiental e na Internet das Coisas precisam conhecer o contexto dos usuários para poder oferecer serviços personalizados. Um componente fundamental do contexto dos usuários são as atividades realizadas diariamente, sendo aplicadas diversas técnicas para reconhecê-las com bases na informação gerada por sensores localizados tanto no ambiente quanto no corpo dos indivíduos.

O reconhecimento de atividades humanas é um campo de pesquisa produtivo e extenso que abrange diversas técnicas de classificação que permitem identificar padrões específicos do comportamento humano no momento da ocorrência. O objetivo deste trabalho foi o desenvolvimento do Sistema de Reconhecimento de Atividades Humanas e Avaliação do Equilíbrio Postural, denominado SIRAH, cujo elemento central é um acelerômetro, localizado na cintura do usuário.

As posturas e atividades a serem identificadas pelo sistema são: posturas ereta, sentada e deitada e atividades: caminhar, correr, sentar-se e levantar-se. No texto são abordadas em detalhe as duas fases envolvidas na construção do sistema: fase *Offline* e fase *Online*. Na fase *Offline* se realizou o treinamento de uma Rede Neural Artificial, do tipo perceptron de três camadas, usando atributos dos sinais de aceleração, gerados nos domínios do tempo e da frequência.

Na fase *Online*, o modelo obtido no treinamento é implementado no próprio sistema SIRAH com o objetivo de classificar dados novos do sensor em tempo real. Desta forma o sistema realiza a classificação das posturas e atividades do usuário no momento da ocorrência.

O sistema SIRAH também avalia a oscilação corporal na postura ereta semi-estática. Acredita-se que a oscilação corporal possui um role importante no controle do equilíbrio (MOE-NILSSEN; HELBOSTAD, 2002). Quando existe disfunção do equilíbrio postural, a amplitude da oscilação corporal pode exceder os limites de estabilidade e contribuir em uma queda. As quedas podem ser o resultado de fatores extrínsecos e intrínsecos, mas a contribuição de cada um muda com a idade. No envelhecimento existe um decremento nas causas externas devido a que a participação em atividades arriscadas diminui. Simultaneamente, existe um aumento das causas intrínsecas devido ao declínio funcional normal relacionado com a idade, pois parte do processo de envelhecimento normal, envolve decrementos nos receptores periférico, na função nervosa, cognição, atenção e na força muscular, altamente envolvidos na regulação de postura ereta. Assim, a disfunção do equilíbrio postural tem sido identificada como um fator de risco importante para futuras quedas, pelo que resulta interessante contar com uma ferramenta para seu análise e quantificação (SAUNDERS, 2013).

O sistema SIRAH calcula a raiz do valor quadrático médio, ou valor RMS (do inglês *Root Mean Square*) da aceleração horizontal e os deslocamentos nos eixos ântero-posterior e médio-lateral do corpo, parâmetros que podem ser usados como indicadores da oscilação do corpo. Nesta aplicação o acelerômetro deve estar localizado no sacro, perto do centro de massa do corpo humano na postura ereta semi-estática.

Este documento está dividido em sete capítulos. No primeiro capítulo são apresentados os objetivos da tese e marco geral da pesquisa, que abrange os conceitos e aplicações da Inteligência Ambiental e a Internet das Coisas. No segundo capítulo apresenta-se o estado da arte do reconhecimento de atividades

humanas com sensores corporais. No terceiro capítulo são explicadas as fases *Offline* e *Online* do reconhecimento de atividades usando acelerômetros, assim como os processos envolvidos em cada fase. No quarto capítulo apresenta-se o sistema SIRAH, explicando as atividades a serem reconhecidas e a localização do sensor, o tipo de acelerômetro e demais elementos de hardware usados. Neste capítulo detalha-se a implementação das duas fases do reconhecimento de atividades do sistema SIRAH, fase *Offline* e fase *Online*, assim como os resultados obtidos em cada processo. No quinto capítulo apresenta-se a implementação da avaliação do equilíbrio postural, os métodos utilizados e resultados do estudo realizado. No capítulo número seis é apresentada a conclusão desta pesquisa e os trabalhos futuros e finalmente no capítulo sete são apresentadas as referências.

## 1.1 OBJETIVOS DA TESE

### 1.1.1 Objetivo geral

Projetar um sistema de monitorização de pessoas, que reconheça atividades humanas e avalie o equilíbrio postural do usuário, baseado na análise das acelerações do corpo.

### 1.1.2 Objetivos específicos

- Estudar a teoria relacionada com o reconhecimento de atividades humanas e suas aplicações;
- Analisar diferentes algoritmos de aprendizagem de máquina, visando sua implementação para reconhecer atividades;
- Estudar o funcionamento de um acelerômetro e sua aplicação no reconhecimento de atividades humanas;

- Projetar um sistema de coleta de dados com o um acelerômetro localizado na cintura;
- Coletar dados e implementar a fase *Offline* do reconhecimento de atividades;
- Implementar a classificação *Online*;
- Analisar e implementar uma metodologia de avaliação do equilíbrio corporal humano baseadas em acelerômetro.

## 1.2 INTELIGÊNCIA AMBIENTAL E A INTERNET DAS COISAS

Na década de oitenta, Mark Weiser, chefe tecnológico da Xerox, publicou um artigo intitulado “O computador do século 21”, que iniciava com a seguinte frase: “As mais profundas tecnologias são aquelas que desaparecem. Elas se entrelaçam com a fábrica da vida diária até serem indistinguíveis” (WEISER, 1991). No artigo, o autor expôs sua visão, segundo a qual, sensores sem fio e computadores tão pequenos que desaparecerão no ambiente, apoiarão aos usuários em todas as atividades diárias. Como estarão distribuídos por todos os lugares, conhecerão as necessidades dos usuários e os ajudarão de acordo as suas necessidades e preferências.

Avanços recentes na computação e na eletrônica possibilitaram pesquisas que aproximam a implementação do paradigma referido por Weiser (1991). Nasceram assim duas áreas complementares: os Ambientes Inteligentes e a Inteligência Ambiental. Um Ambiente Inteligente é um lugar enriquecido com tecnologia, com o objetivo de melhorar os serviços que podem ser oferecidos. A Inteligência Ambiental (*Ambient Intelligence*, Aml) eleva o comportamento global de um Ambiente Inteligente. Este conceito refere-se aos espaços físicos enriquecido com sensores, atuadores e *software* que ajudam as pessoas no desenvolvimento das atividades diárias. O desenvolvimento da Aml, está baseado na maturidade alcançada em várias áreas da computação, organizadas em Augusto *et al.* (2013) em cinco campos: sensores e atuadores, Inteligência Artificial (IA), computação

ubíqua, redes de comunicação e programas mediadores (*Middleware*) e interfaces homem-máquina:

- Os sensores são os componentes físicos que permitem ao sistema conhecer o que está acontecendo no ambiente e atuar através dos atuadores (COOK; AUGUSTO; JAKKULA, 2009);
- A Inteligência Artificial é o ramo que abrange as técnicas que permitem aos sistemas oferecer serviços da mesma forma que as pessoas o fariam em circunstâncias similares;
- A computação ubíqua é um paradigma que explora o desenvolvimento de sistemas descentralizados que acompanham os usuários em todos os lugares;
- As redes são usadas para transmitir as informações dos sensores até os programas mediadores que facilitam a interoperabilidade entre as partes do sistema;
- As interfaces homem-máquina são as ferramentas que possibilitam a interação com sistemas, sem a necessidade de muito treinamento e especialização (WEISER, 1991).

Os espaços contemplados com Aml identificam o contexto do usuário; devido às informações fornecidas por sensores, são personalizados, antecipam-se as necessidades e adaptam-se as mudanças (ACAMPORA *et al.*, 2013).

A Internet das Coisas, IoT (*Internet of Things*) é a continuação natural da Aml. De acordo com este conceito, os sensores, os atuadores e os objetos com etiquetas RFID (*Radio Frequency Identification*), estão conectados em rede e com a Internet. Assim, adquirem a capacidade de compartilhar dados e interagir mutuamente, usando diversos protocolos e tecnologias, para oferecer serviços de valor agregado, que não seria possível se estivessem isolados (YACHIR *et al.*, 2016).

As “Coisas” podem ser sensores, dispositivos com computação embarcada ou sistemas embarcados, que podem transmitir e receber informação para controlar

outro dispositivo ou interagir com um usuário. Como exemplo de uma “Coisa” tem-se um sensor de temperatura, um microcontrolador ou um dispositivo baseado em um microcontrolador. Por outro lado, um forno de micro-ondas, uma casa, uma lavadora de roupa não estão sob a definição de “Coisas”; porém a IoT toma estas entidades físicas e as integra com computação e networking. Para entrar na definição de “Coisa” um dispositivo deve realizar alguma das seguintes tarefas:

- Identificar e armazenar informação;
- Coletar informação;
- Entender comandos;
- Transmitir e receber mensagens;
- Detectar;
- Atuar (MOHANTY; CHOPPALI; KOUGIANOS, 2016).

Os conceitos da Aml e da IoT estão sendo estudados há vários anos, porém, sua implementação ainda está em andamento. Espera-se que aproximadamente 50 bilhões de dispositivos estejam conectados à Internet em 2020 (LARA; LABRADOR, 2013); contudo, os 99% das coisas disponíveis hoje, ainda não estão conectadas em rede. Segundo uma reportagem de Navigant, o número de medidores inteligentes instalados no mundo crescerá até 1,1 bilhões em 2022. Em outra reportagem da Automotive News, indica-se que o número de carros conectados à Internet aumentará de 23 milhões em 2013 até 152 milhões em 2020. A previsão de tamanho crescimento mostra que a IoT será a fábrica da sociedade moderna para concretizar a visão dos Ambientes Inteligentes (AHMED *et al.*, 2016).

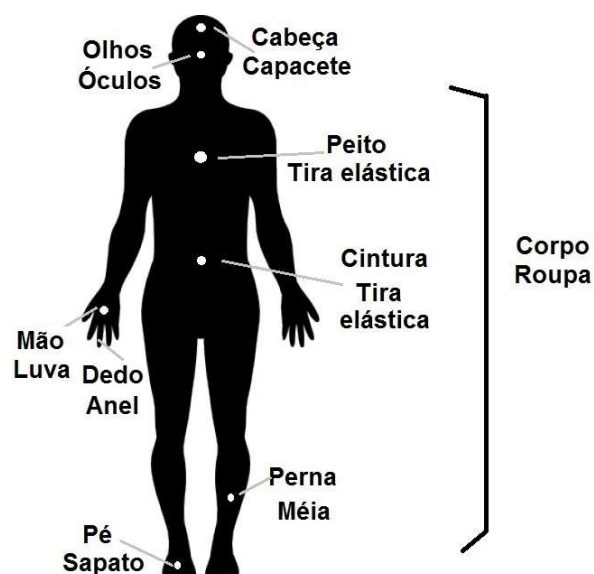
### 1.3 APLICAÇÕES DA INTELIGÊNCIA AMBIENTAL E A INTERNET DAS COISAS

O trabalho na Inteligência Ambiental baseada na IoT é extenso e complexo, e pode ser classificado de diversas formas. Nesta pesquisa são apresentados diversos exemplos de aplicações, organizados nas áreas de *smart wearables*, casas inteligentes e cidades inteligentes, seguindo parte do enfoque apresentado em Perera, Liu e Jayawardena (2015) e dando-se maior importância principalmente nas duas primeiras áreas, nas que se enquadra o foco deste trabalho.

#### 1.3.1 Smart wearables ou wearable sensors

Nesta área estão agrupados os dispositivos eletrônicos que podem ser usados no corpo. As soluções “vestíveis” estão projetadas para serem usadas em diferentes partes e com diversos propósitos, como pode-se ver na Figura 1.

Figura 1 - Diferentes partes do corpo as que são dirigidas as aplicações da Aml e IoT.



Fonte: Adaptada de Perera, Liu e Jayawardena (2015).

No Quadro 1 são indicadas algumas aplicações apresentadas em Perera, Liu e Ayawardena (2015) que estão no mercado atual, junto com outras encontradas na pesquisa.

Quadro 1 - Funcionalidades oferecidas por alguns smart wearables.

Local	Funcionalidade
Roupa	Roupa de bebê com sensores de temperatura, som e movimento que permitem conhecer a posição do corpo e mudanças de atividade, qualidade de sono, áudio e a respiração do bebê (MIMO <sup>1</sup> ).
Cabeça/pescoço	<i>Airbag</i> para ciclistas. Dispositivo com sensores que pode monitorar os movimentos do ciclista e reagir se detectar um acidente, inflando um <i>airbag</i> fixo no pescoço que absorve o impacto, protegendo desta maneira a cabeça (Hövding <sup>2</sup> ).
Peito	Monitor de postura; através de sensores detecta a melhor postura do usuário. Quando este inclina-se para a frente ou para atrás o sistema vibra encorajando-o para melhorar sua postura, seja sentado ou parado (LUMO) <sup>3</sup> .
Punho	Monitor de atividade que fornece o número de passos, distância percorrida e calorias consumidas no dia, o que permite estabelecer metas e monitorar o progresso (Fitbit) <sup>4</sup> .
Mãos	Luva equipada com sensores de movimento que medem aspectos dos movimentos realizados no golfe, baseball, tênis. Também existe um sensor específico para ser usado na panturrilha por jogadores de futebol. Em todos os casos o sistema retroalimenta ao usuário com indicações para melhorar no treinamento (Zepp) <sup>5</sup> .

<sup>1</sup> <http://mimobaby.com/>

<sup>2</sup> <http://www.hovding.com/>

<sup>3</sup> <http://www.lumobodytech.com/lumo-lift/>

<sup>4</sup> <https://www.fitbit.com/>

<sup>5</sup> <http://www.zepp.com/en-us/>

Pernas/pês	Meias que combinam acelerômetros com sensores têxteis para monitorar o número de passos e a distância diariamente (Sensoria) <sup>6</sup> .
------------	---

Fonte: Adaptada de Perera, Liu e Jayawardena (2015).

### 1.3.2 Casas inteligentes

A aplicação mais conhecida na área da Inteligência Ambiental e a Internet das Coisas é a das casas inteligentes, mas de igual maneira hospitais, carros, salas, ruas e outros lugares estão sendo considerados. O alvo das aplicações abrangidas neste campo consiste em fazer a experiência de viver em uma casa, mais conveniente e agradável para o habitante.

No campo médico, uma casa inteligente é um ambiente que possibilita o monitoramento de pessoas idosas, com alguma doença crônica ou uma deficiência. Devido as características dos sistemas de saúde da maioria dos países industrializados, os cidadãos estão enfrentando dificuldades relacionadas à qualidade e custo dos serviços médicos. Estes problemas se acentuarão com o envelhecimento da população, sendo que o uso das tecnologias da Aml e a IoT nas casas, oferecem a possibilidade de implementar sistemas autônomos e proativos, fato que traria benefícios extremamente grandes na sociedade, reduzindo os custos dos serviços de saúde e aumentando a qualidade de vida dos usuários. Em Acampora *et al.* (2013) são expostos diversos trabalhos específicos da Aml e a IoT, classificados de acordo ao seu objetivo geral, como por exemplo:

- Monitoramento contínuo da saúde: a ideia de monitorar continuamente um paciente é muito difícil nos sistemas de saúde convencionais, nos quais os exames e avaliações são feitos unicamente nas visitas esporádicas ao médico. Com a utilização de sensores corporais é possível monitorar os sinais fisiológicos de um paciente continuamente e de uma maneira não-

<sup>6</sup> <http://www.sensoriafitness.com/>

invasiva. Um ou vários sensores coletam os dados em tempo real e os transmitem a um *smartphone*, um computador ou diretamente à Internet. Estes dados são armazenados e analisados, o que permite aos cuidadores monitorar os pacientes de qualquer local e responder adequadamente. Os sistemas associados também podem identificar anomalias e enviar alarmes quando for necessário;

- Monitoramento contínuo do comportamento: além dos sinais fisiológicos, outra potencial aplicação nas casas inteligentes é o monitoramento do comportamento. Estes sistemas podem avaliar a saúde mental e o estado cognitivo de pacientes com deficiências mentais, analisando as atividades diárias de pacientes com demência e identificando consistência (inconsistência) nessas atividades;
- Terapia e reabilitação física: existem pesquisas que analisam os movimentos de um indivíduo necessários no tratamento de reabilitação. Se o sistema detectar divergências entre os movimentos do paciente e os movimentos objetivo, tanto paciente como seu terapeuta podem ser informados. Também têm sido propostos trabalhos relacionados com reabilitação para doenças degenerativas como Parkinson, para estimar a severidade dos sintomas e complicações de pacientes, como tremor, lentidão de movimento, ou movimentos não intencionais, involuntários e incontroláveis;
- Persuasão para o bem-estar: neste grupo estão reunidas aquelas aplicações que pretendem fazer que pessoas mudem algum tipo de atitude ou comportamento. O estilo de vida dos habitantes pode ser analisado através de sensores localizados na casa. O sistema de Aml pode enviar retroalimentação continua tentando motiva-los a levar uma vida mais saudável, por exemplo, incentivando-as para deixar de fumar, a comer mais frutas, a fazer atividade física etc. Estas aplicações também podem ser usadas nas academias para persuadir aos usuários ou em um coletivo de pessoas para a diminuição da poluição ambiental;

- Bem-estar emocional: estudos recentes demonstraram a importância das emoções em vários aspectos, principalmente nas áreas da saúde e do bem-estar. A Aml e IoT podem ser ferramentas importantes para conhecer e gerenciar emoções, que normalmente são comunicadas através da voz, do rosto, dos gestos, da pressão sanguínea, dos batimentos do coração e da respiração. Aplicações neste campo abrangem identificação de características da voz, como amplitude, velocidade da fala, duração das pausas para identificação dos momentos de estresse ou prazer do usuário. Também podem ser usadas informações das atividades do usuário obtidas com base nos sensores corporais que, combinadas com a história psicológica e psiquiátrica do paciente, ajudam no monitoramento de pacientes com transtorno bipolar ao longo prazo;
- Hospitais inteligentes: as tecnologias da Aml e IoT podem ser usadas para melhorar a comunicação e a tomada de decisões entre enfermeiras, médicos e empregados de um hospital, baseadas em informações do contexto, como localização, tempo, função das pessoas presentes, histórico do paciente, entre outras;
- Ambientes de vida assistida, (*Ambient Assisted Living, AAL*): Nos AAL as tecnologias Aml e IOT permitem que pessoas com certas deficiências, doenças crônicas ou idosos possam viver de uma maneira mais independente, de forma conveniente e com segurança. Entre as aplicações que existem neste campo está a detecção de quedas, que são uma das causas mais comuns de morbidez e morte de idosos. Após a detecção da queda pode ser ativado um alarme, seguido do envio de uma mensagem de alerta para os familiares e/ou cuidadores do paciente. Em relação a pacientes com demência, podem ser enviados lembretes das atividades diárias. Além disso, podem ser projetados sistemas para prevenir que eles perambularem, detectando se eles saírem de rotas predefinidas e avisando a seus cuidadores.

Para pessoas com deficiência visual têm sido propostos vários projetos, com a meta de oferecer navegação cega, baseados em etiquetas RFID, sensores infravermelhos e tecnologia GPS (*Global Positioning System*).

Outras aplicações apontam a solucionar o problema da gerencia dos medicamentos, muito importante para os idosos, com o desenvolvimento de prototipos de caixas médicas inteligentes, que possuem diversos sensores e etiquetas RFID para controlar a ingesta dos remedios. Esta aplicação foi apresentada em Islam *et al.* (2015).

Nos últimos anos, o campo médico e da saúde, tem chamado a atenção dos pesquisadores, que vem o potencial das possíveis aplicações da Aml e a IoT na solução de desafios práticos. Contudo, as aplicações continuam em sua infância neste campo; ainda existem aspectos inacabados tanto nos serviços prestados, quanto na padronização, plataformas, protocolos, escalabilidade, entre outros (ISLAM *et al.*, 2015). No mercado é possível encontrar alguns produtos como Smartcaregiver<sup>7</sup> com aplicações de detecção de quedas e anti-perambulantes.

No campo da construção civil, uma casa ou um edificio inteligente pode ter diferentes classes de *hardware*, *software*, sensores e aplicações de automação, incluindo redes de dados, Voz sobre IP (também chamada de VoIP), distribuição de video, controle de aceso, controle de luzes, vídeo-vigilância e gerenciamento de energia (MOHANTY; CHOPPALI; KOUGIANOS, 2016). Control touch<sup>8</sup> e Cybertronics<sup>9</sup> são exemplos de produtos que oferecem estes serviços.

### 1.3.3 Cidades inteligentes

Uma cidade inteligente é um conceito do qual existem diversas definições formais entre acadêmicos e profissionais. Segundo uma delas, uma cidade

---

<sup>7</sup> <http://smartcaregiver.com/>

<sup>8</sup> <http://controltouch.com.br/automacao/>

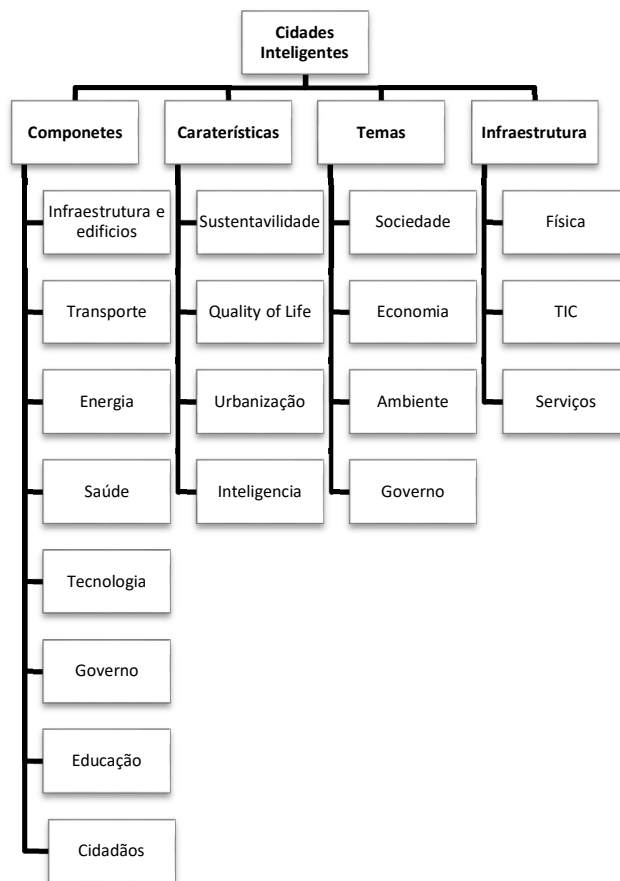
<sup>9</sup> <http://www.cybert.com.br/index.php/home?view=featured>

inteligente é uma cidade inovadora, que usa as Tecnologias da Informação e Comunicação (TIC), e outros meios para melhorar a qualidade de vida e a eficiência das operações e serviços urbanos, enquanto atende as necessidades das gerações presentes e futuras, nos aspectos econômico, social e ambiental (MOHANTY; CHOPPALI; KOUGIANOS, 2016).

Alguns dos componentes e características de uma cidade inteligente são apresentados na Figura 2. Qualquer combinação de vários componentes pode tornar uma cidade inteligente. O número de componentes depende do custo e da tecnologia disponível.

Cada um dos componentes se diferencia do seu par tradicional, no sentido da cooperação entre sistemas e a eficiência e rapidez dos processos. Por exemplo, nos sistemas de transporte inteligentes, *Intelligent Transportation Systems* (ITS), são integradas as TIC com infraestruturas de transporte, veículos e usuários finais. Estes sistemas aumentam a mobilidade dos recursos para os cidadãos, as sociedades e economias. Também incorporam segurança e características de navegação, informação e lazer, impactando positivamente no meio ambiente, no crescimento econômico, nas exportações globais e nas oportunidades de emprego. Por todas estas razões são considerados requerimentos básicos no desenvolvimento sustentável das cidades modernas (RAFIQ, *et al.*, 2013).

Figura 2 - Componentes e características das cidades inteligentes.



Fonte: Adaptada de Mohanty, Choppali e Kougianos (2016).

Os ITS incluem vários tipos de sistemas de comunicação e navegação usados entre veículos, assim como entre veículos e locais fixos. Um ITS abrange sistemas ferroviários, aquáticos e aéreos assim como suas interações. Isto permite que um usuário possa selecionar facilmente a melhor opção de transporte, tomando em conta o menor preço, distancia mais curta ou rota mais rápida. Tudo isto é possível devido ao uso das TIC e do processamento de dados em tempo real (MOHANTY; CHOPPALI; KOUGIANOS, 2016).

Exemplos específicos dos ITS incluem sistemas de estacionamento, como o SmartParking<sup>10</sup>, que otimizam o uso do espaço e o tempo gasto pelo motorista, quem é guiado até o estacionamento mais conveniente a através de sensores,

<sup>10</sup> <http://www.smartparking.com/>

informação do contexto em tempo real e serviços de localização. Também existem sistemas para solicitar taxi através do smartphone, como Uber, e sistemas como o Alltrafficsolutions<sup>11</sup>, que coletam dados do trânsito e os apresentam em mapas com a finalidade de manter atualizados aos motoristas (PERERA; LIU; JAYAWARDENA, 2015).

Um componente fundamental dos sistemas aplicados na Aml e a IoT para conhecer o contexto, é o uso de diferentes tipos de sensores para detectar e classificar as atividades realizadas pelos usuários. O reconhecimento de atividades humanas (*Human Activity Recognition*, HAR) é um ponto essencial que permite oferecer serviços personalizados. Existem, por exemplo atividades críticas, como as quedas, que precisam de atenção medica imediata, e não criticas, como sentar-se ou caminhar, que podem prover informação valiosa no monitoramento de doenças cronicas, habilidades funcionais e no diagnostico temprano (ERDEN *et al.*, 2016).

Na área de HAR encontram-se diversas técnicas de classificação que permitem identificar a qual categoria pertencem novos dados gerados pelos sensores, com base em um conjunto de treinamento. Deste modo, se conforma um campo de pesquisa produtivo e extenso, foco desta pesquisa e que é tratado com profundidade no capítulo seguinte.

---

<sup>11</sup> <http://www.alltrafficsolutions.com/>

## 2 ESTADO DA ARTE: RECONHECIMENTO DE ATIVIDADES

O HAR é uma área em desenvolvimento com o objetivo de identificar padrões específicos de comportamento humano, com base nos dados obtidos por diversos sensores (ACAMPORA *et al.*, 2013). Os primeiros trabalhos na área datam do final dos anos 90; contudo, ainda existem aspectos que motivam o desenvolvimento de novas técnicas com vista a melhorar a precisão do sistema, sobre condições realistas de funcionamento. O HAR possui dois aspectos fundamentais: atividades a serem identificadas e o/os sensor/es usados.

### 2.1 ATIVIDADES A SEREM IDENTIFICADAS

As atividades realizadas por uma pessoa na vida diária são classificadas por Cornacchia *et al.* (2017) em dois grupos: atividades globais e atividades envolvendo interações locais, designadas no Quadro 2 como Agrupamento 1. As atividades globais são aquelas que precisam do deslocamento total do corpo. Por sua vez, estas são subdivididas em atividades ambulatorias, de transporte e de atividade esportiva por Lara e Labrador (2013), denominadas no Quadro 2 como Agrupamento 2. As atividades locais são as que envolvem interações entre as extremidades do corpo humano e algum objeto. Estas também são apresentadas na Quadro 2 e abrangem o uso do celular e diversas atividades diárias.

Quadro 2 - Tipos de atividades reconhecidas por sistemas HAR.

<b>Agrupamento 1</b>	<b>Agrupamento 2</b>	<b>Atividades</b>
<b>Globais</b>	<b>Ambulatórias</b>	Caminhar, correr, sentar-se, deitar-se, subir e descer escadas, escada rodante e subir elevador.
	<b>Transporte</b>	Andar de ônibus ou de bicicleta e dirigir.
	<b>Atividade esportiva</b>	Remo, levantamento de pesos, fiação, marcha nórdica, flexões.
<b>Interação local</b>	<b>Uso do celular</b>	Mandar mensagem, ligar.
	<b>Atividades diárias</b>	Comer, beber, trabalhar no computador, assistir televisão, ler, escovar os dentes, esfregar e aspirar.
<b>Outras</b>	<b>Militares</b>	Rastejando, ajoelhado, avaliação da situação e abertura de uma porta.
	<b>Tronco</b>	Mastigar, falar, engolir, suspirar e mover a cabeça.

Fonte: Adaptada de Cornacchia et al. (2017) e Lara e Labrador (2013).

## 2.2 SENSORES APLICADOS NO HAR

Os sensores usados na identificação de atividades, fornecem uma variedade de informações que podem ir desde simples valores *on/off*, valores numéricos ou faixas de valores, até sons ou imagens. Não existe uma fórmula única para combinar sensores em uma aplicação específica, sendo que nas pesquisas atuais

são combinados vários tipos de sensores, de maneira que se ajustem ao problema específico (AUGUSTO *et al.*, 2013).

Em relação à localização dos sensores no HAR, estes podem ser divididos em dois grupos: sensores fixos e sensores corporais. Os sensores fixos estão situados no ambiente em que se realiza a atividade. A identificação depende da interação voluntária do usuário com o sensor. No Quadro 3 são apresentados diversos tipos de sensores fixos e seus usos nos sistemas HAR.

Quadro 3 - Sensores fixos com possíveis aplicações no HAR.

Sensor fixo	Aplicação
PIR <sup>12</sup>	<ul style="list-style-type: none"> <li>• Controlar a televisão através da classificação dos movimentos da mão, detectados por um arranjo de três sensores (ERDEN; ÇETIN, 2014);</li> <li>• Capturar o nível geral de atividade física do habitante baseado na quantidade do movimento detectado por sensores espalhados nos quartos da casa (SKUBIC; GUEVARA; RANTZ, 2015);</li> <li>• Estabelecer um padrão de atividade de um idoso, identificando tanto sua localização como seu movimento, através de sensores situados em pontos focais da casa (SURYADEVARA; MUKHOPADHYAY, 2014);</li> </ul>
Vibração	<ul style="list-style-type: none"> <li>• Detecção de quedas de idosos, diferenciando-as de atividades normais pelos sinais de vibração gerados por sensores localizados nos quartos (YAZAR <i>et al.</i>, 2013);</li> </ul>
Etiquetas RFID <sup>13</sup>	<ul style="list-style-type: none"> <li>• Localização de objetos e reconhecimento de atividades usando etiquetas em objetos da casa (FORTIN-SIMARD <i>et al.</i>, 2015);</li> <li>• Identificar interações dos usuários em ambientes assistidos, usando etiquetas nos objetos, por exemplo em livros (PARADA</li> </ul>

<sup>12</sup> Pyroelectric ("Passive") InfraRed Sensors

<sup>13</sup> Radio Frequency Identification

	<i>et al.</i> , 2015);
Força	<ul style="list-style-type: none"> <li>• Detectar atividades diárias, quedas e localização de humanos, objetos e robôs com células de carga <i>strain gauge</i> localizadas nas bordas inferiores de azulejos (DAHER <i>et al.</i>, 2017), (ANDRIES; SIMONIN; CHARPILLET, 2016);</li> <li>• Identificar padrões na marcha em um tapete baseado em fibra ótica plástica sensível à deformação quando a força é aplicada na marcha (COSTILLA-REYES; SCULLY; OZANYAN, 2016);</li> <li>• Reconhecer atividades usando sensores piezoelétricos no chão (SERRA <i>et al.</i>, 2016);</li> </ul>
Pressão	<ul style="list-style-type: none"> <li>• Identificar atividades relacionadas à alimentação com uma matriz de sensores de pressão embutidos numa toalha de mesa (ZHOU, <i>et al.</i>, 2015);</li> <li>• Identificar desvio nos padrões de atividades diárias para gerar alarmes. Entre os sensores usados está um sensor de pressão localizado na cama (HAJIHASHEMI; YEFIMOVA; POPESCU, 2014);</li> </ul>
Câmeras fixas;	<ul style="list-style-type: none"> <li>• Reconhecer ações humanas, com base na análise de vídeos (CHUN; LEE, 2016) (YANG; TIAN, 2016) (WANG <i>et al.</i>, 2016) (GAGLIO; RE; MORANA, 2015) (BANERJEE <i>et al.</i>, 2014).</li> </ul>

Fonte: Elaboração da própria autora.

Diversas pesquisas têm usado câmeras no HAR. Porém, questões como a limitação do monitoramento aos espaços nos quais estes sensores estejam instalados, a complexidade das técnicas de processamento de imagens e a constante vigilância à que estão sujeitos os usuários, sendo constantemente filmados, afetando sua privacidade, fizeram que os sensores corporais começassem a serem usados (BULLING; BLANKE; SCHIELE, 2014). Estes sensores permitem coletar dados durante longos períodos de tempo, sob

condições da vida cotidiana devido ao fato de não apresentarem muitos inconvenientes para o usuário.

Inicialmente os sensores corporais eram grandes, pesados e usados principalmente em instalações médicas. Porém, vários acontecimentos geraram uma transformação na preferência dos usuários, sendo que hoje em dia é possível encontrar smartphones e relógios com sensores fazendo parte da vida diária das pessoas, permitindo que o HAR com sensores corporais seja uma aplicação factível e acessível (CORNACCHIA *et al.*, 2017). Entre estes fatos estão a aceitação cultural dos dispositivos móveis, o mercado dos *smartphone* e as diversas pesquisas no desenvolvimento dos sistemas microeletrônicos MEMS (*microelectromechanical system*). Os MEMS são uma tecnologia para o projeto de sensores baseada na miniaturização de elementos mecânicos e eletrônicos, produzidos usando tecnologia de microfabricação. Recentemente os MEMS têm sido utilizados na fabricação de diferentes tipos de sensores como acelerômetros (ACAMPORA *et al.*, 2013). Entre os sensores corporais mais usados no âmbito do HAR estão os acelerômetros, magnetômetros, giroscópios e as câmeras.

### 2.3 RECONHECIMENTO DE ATIVIDADES COM SENSORES CORPORAIS

Em Cornacchia *et al.* (2017) os autores oferecem uma revisão recente de trabalhos de detecção e classificação de atividades baseada em sensores corporais, proporcionando uma visão atualizada dos tipos de sensores e aplicações, assim como o desenvolvimento através dos anos desta área de pesquisa.

Seguindo a descrição proposta neste trabalho, na sequência são apresentadas diversas pesquisas distribuídas segundo o tipo de sensor aplicado no sistema, a localização no corpo e o número de dispositivos usados.

Na medida em que se usa determinado sensor ou uma mistura deles em diversas partes do corpo, o sistema possui habilidades para distinguir distintas

atividades. Por exemplo, as atividades globais têm sido reconhecidas geralmente usando dados gerados por acelerômetros/magnetômetros/giroscópios (A/M/G), enquanto os sistemas baseados em câmeras fornecem mais informação necessária na abordagem de atividades locais. Os sistemas híbridos usam uma mistura de sensores que oferece informação para determinar atividades tanto globais quanto locais.

### **2.3.1 Reconhecimento de atividades com acelerômetros, magnetômetros e/ou giroscópios**

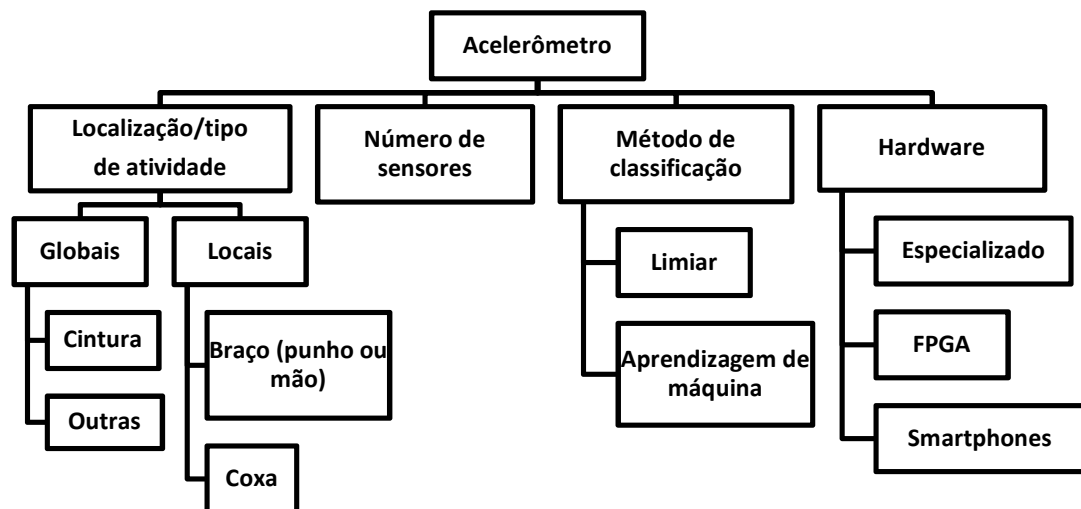
Nos sistemas de HAR baseados em acelerômetros existem duas características que podem ser extraídas dos sinais de aceleração: atributos no domínio do tempo (como a média aritmética, desvio padrão, correlação, entre outros), e atributos no domínio da frequência (como a energia, entropia espectral, entre outros). Na maioria dos trabalhos são empregados os dois tipos de atributos mencionados.

Os acelerômetros são amplamente usados no HAR e os trabalhos com estes sensores são tão diversos que podem ser examinados tomando em conta as atividades a identificar, a localização do sensor no corpo, o número de dispositivos usados, o método de classificação e o hardware utilizado, como é apresentado na Figura 3. Na sequência serão considerados os trabalhos de HAR baseados no uso de acelerômetros, separados tomando em conta o tipo de atividade a identificar.

A localização do acelerômetro no corpo do usuário praticamente determina o tipo de atividade a identificar. Para a identificação de atividades globais, estes sensores são colocados principalmente na cintura; porém, também existem trabalhos nos que estes sensores são aplicados em outros lugares centrais, como o peito ou a parte baixa das costas. Na identificação de atividades de interação local os acelerômetros são utilizados principalmente nas extremidades. Contudo,

estas posições (nas extremidades) também tem sido usada no estudo de atividades globais, mas em menor medida.

Figura 3 - Enfoques no estudo do uso de acelerômetros no HAR.



Fonte: Adaptada de Cornacchia *et al.* (2017).

### 2.3.1.1 Localização para identificação de atividades globais

Para reconhecer atividades globais, em vários trabalhos o acelerômetro é posicionado na cintura. Este é um ponto próximo ao centro de massa do usuário, que permite obter informações de interesse, utilizando um único dispositivo (MATHIE *et al.*, 2004). Além disso, a cintura é um lugar conveniente para acomodar o sistema em um cinto, proporcionando às pessoas facilidade no uso.

Os primeiros trabalhos, baseados nesta configuração, realizaram a classificação com um limitado conjunto de atributos e um único algoritmo de classificação. Em Baek *et al.* (2004) identificaram 8 atividades, tanto estáticas quanto dinâmicas, com base em 10 atributos no domínio no tempo, usados como entrada de um algoritmo de classificação. Outros trabalhos não usaram um algoritmo para a classificação, mas sim limiares, empiricamente determinados

para cada atividade como em Karantonis *et al.* (2006). Posteriormente estes limiares foram usados para diferenciar atividades dinâmicas, como caminhar ou correr, das estáticas, como ficar parado ou deitado. Após identificar a qual dos grupos corresponde a atividade sendo realizada, um outro método realiza a classificação final. Em Zhang *et al.* (2010) os autores usaram raciocínio baseado em regras para diferenciar as atividades estáticas das dinâmicas e a classificação final é realizada através de máquinas de suporte vetorial (*support vector machine*, SVM). Outra tendência na área foi comparar diversos algoritmos de classificação. Em Ravi *et al.* (2005) são comparados diversos algoritmos, baseados em um conjunto de 12 atributos no domínio do tempo e da frequência.

Trabalhos mais recentes, como Wang *et al.* (2016), Capela (2015), Gupta e Dallas (2014) e Arif *et al.* (2014), continuam com o objetivo de comparar algoritmos, mas focam esforços na escolha do grupo de atributos usados como entradas, aspecto que pode melhorar o desempenho na classificação.

Outras novidades estão relacionadas com a possibilidade de diferenciar níveis de intensidade de atividades (ALSHURAFI *et al.*, 2014), ou melhorar o consumo de potência, mantendo o desempenho na classificação (ANGUITA *et al.*, 2013).

A cintura não é o único lugar central do corpo utilizado para identificar atividades globais. Também têm sido usados outros lugares centrais como o peito e a parte baixa das costas para a colocação do sensor. Em Safadi *et al.* (2016) o acelerômetro é localizado no sacro com o objetivo de reconhecer atividades globais realizadas com diferentes velocidades.

Existem trabalhos focados no reconhecimento de atividades globais, nos que o acelerômetro é usado nas extremidades. Em Kwapisz, Weiss e Moore (2011) são classificadas atividades globais usando o acelerômetro de um smartphone levado no bolso frontal da calça. No trabalho são comparados três algoritmos com base em um conjunto de 43 atributos no domínio do tempo. Em Mannini e Sabatini (2011) o acelerômetro é usado na coxa com a finalidade de

reconhecer atividades e estimar a velocidade do usuário quando este caminha ou corre. Em da Silva e Galeazzo (2013) e Margarito *et al.* (2016) com um acelerômetro situado no punho podem-se identificar atividades globais e esportivas respectivamente. Os dois trabalhos comparam o desempenho de vários algoritmos com base em conjuntos de atributos tanto no domínio do tempo como da frequência. Em McCarthy *et al.* (2015) foi usado um giroscópio no pé para classificar atividades caminhar, correr, subir e descer escadas empregando uma árvore de decisão.

O acelerômetro também tem sido usado na detecção de quedas. Em Pannurat, Thiemjarus e Nantajeewarawat (2017) analisaram diversas localizações do acelerômetro no corpo, e encontraram que o melhor desempenho é obtido quando usado ao lado da cintura e no peito, seguido pela cabeça, à frente da cintura, o punho, o tornozelo, a coxa e o braço.

Outros pesquisadores exploraram o uso de dois ou mais acelerômetros, com o objetivo de descobrir a melhor posição para classificar atividades globais, aumentar o número de atividades ou melhorar a precisão da classificação. O fato de aumentar o número de sensores usados implica também o aumento de complexidade nos métodos de classificação. Por exemplo, em Maurer *et al.* (2006) são usados 6 acelerômetros no punho, cinto, pescoço, bolso direito das calças, bolso da camisa e bolsa, para estudar posições onde são usados dispositivos eletrônicos, como por exemplo, os telefones celulares. No estudo foram analisados vários conjuntos de atributos no domínio do tempo com vários algoritmos para encontrar a melhor posição para as atividades escolhidas.

Os trabalhos que não se enfocam no uso de múltiplos sensores, distinguem-se pela implementação em hardware. Kailas (2012) propôs o uso do hardware disponível, utilizando um chip com acelerômetro e giroscópio para a coleta de dados. Basterretxea, Echanobe e del Campo (2014) apresentaram um sistema de classificação baseado em um FPGA (*Field Programmable Gate Array*, Arranjo de Portas Programáveis em Campo), que inclui todos os processos necessários, desde a segmentação até a classificação baseada em uma rede

neural artificial, RNA, treinada previamente no computador. Diversos trabalhos usaram os acelerômetros e giroscópios embutidos dos smartphones, como Beily *et al.* (2016), Wannenburg e Malekian (2016) e Bisio *et al.* (2016). Nos trabalhos observados o telefone foi usado para coletar dados e classificar, enquanto o treinamento foi realizado em um computador.

### **2.3.1.2 Localização para atividades de interação local**

No reconhecimento de atividades que envolvem interação local, a maioria dos trabalhos posicionam os sensores no braço e se diferenciam, principalmente, pelo número de dispositivos utilizados.

Os sistemas de reconhecimento de atividades que envolvem interação local, baseados em um único sensor, geralmente o aplicam no punho e empregam métodos baseadas em limiares. No seu primeiro trabalho Min, Ince e Tewfik (2007), usaram um acelerômetro no punho para classificar atividades típicas das manhãs, como escovar os dentes, lavar o rosto, lavar as mãos e barbear-se, aplicando um método de limiares. Em seus outros trabalhos Min, Ince e Tewfik (2008) e Min, Ince e Tewfik (2008) incluíram um sensor fixo de movimento e um sensor acústico respectivamente, para aumentar o número de atividades a 6, incluindo o uso de escova e barbeador elétricos. Em Fortune *et al.* (2011) foram usados um acelerômetro e um giroscópio na coxa para identificar atividades como vestir-se, escrever, limpar, dobrar roupa, entre outros.

Com o intuito de identificar um maior número de atividades, pesquisadores têm explorado sistemas com mais de um acelerômetro. Em Lin *et al.* (2012) usaram 3 acelerômetros localizados no punho, na cintura e tornazelo. O sistema utiliza uma RNA para detectar 14 atividades e estima o gasto energético diário. Em Min e Cho (2011) são usados 5 pares de acelerômetros e giroscópios para identificar 19 atividades incluindo bater palmas, escovar dentes entre outras.

### 2.3.2 Reconhecimento de atividades com câmeras e outros sensores

Através dos anos, os sistemas de HAR baseados no uso de câmeras no corpo, têm-se desenvolvido devido à diminuição do tamanho destes dispositivos assim como ao aumento da resolução e da velocidade de processamento. Na maioria dos trabalhos a câmera está localizada na cabeça ou no tronco do usuário.

Da mesma forma como acontece com os sistemas baseados em acelerômetros, os sistemas baseados em câmeras podem ser analisados dependendo do tipo de atividade a identificar. Existem trabalhos em que as atividades globais são identificadas com câmeras, porém, estas pesquisas não necessariamente aproveitam a quantidade de detalhes visuais capturados por estes sensores, que permite diferenciar atividades de interação local finas, como por exemplo, fazer café ou fazer chá.

A identificação de atividades de interação local é analisada como um processo que envolve uma pessoa e sua interação com um objeto, ou a interação entre várias pessoas. Entre as atividades de interação local identificadas através de câmeras localizadas no corpo estão: atividades de higiene pessoal, comer, limpeza da casa, preparação de alimentos e atividades de escritório.

Com os avanços nos sistemas de *gaming* como o Kinect, os sensores Red, Green, Blue e Depth (RGBD-D), tem aumentado sua popularidade e também têm sido incluídos nos trabalhos de HAR. Em Moghimi *et al.* (2014) uma câmera RGBD-D montada em um capacete é usada para classificar atividades, com base nos algoritmos RNC (Redes neurais convolucionais) e SVM.

Entre os outros tipos de sensores usados no HAR estão as etiquetas RFID, e sensores customizados (*custom-built*). Em Wang *et al.* (2017) é apresentado um sistema de reconhecimento de atividades RFID, que usa 4 antenas aplicadas no corpo, uma no peito, uma nas costas e uma em cada pé, assim com 9 etiquetas passivas, uma em cada braço, punho, tornozelo, perna e uma no corpo para

extrair o padrão de radiação e extrair atributos espaciais e temporais. Em Cheng *et al.* (2013) são mostrados sensores construídos a partir de fragmentos condutores têxteis, que permitem monitorar a taxa de respiração e o batimento cardíaco. Em Wujcik *et al.* (2013) são mostrados sensores iônicos para medir a quantidade de íons de sódio no suor em tempo real.

### **2.3.3 Reconhecimento de atividades com sistemas híbridos**

Os sistemas híbridos são aqueles que possuem mais de um tipo de sensor. É possível encontrar sistemas híbridos que combinam acelerômetros com diversos tipos de sensores, como câmeras, sensores RFID, ECG ou sensores de pressão, para identificar tanto atividades globais como de interação local; a maioria emprega métodos de aprendizado supervisionado.

Em Nam Rho e Lee (2013) utilizaram um acelerômetro junto com uma câmera, com a finalidade de aumentar a precisão na classificação de atividades ambulatorias; em Wu, Lemaire e Baddour (2011) e Doherty *et al.* (2013) usaram um acelerômetro para detectar o nível de atividade sendo realizada, e a informação do contexto fornecida por câmeras para identificar a atividade específica. Em Zhan, Faux e Ramos (2015) desenvolveram um sistema de acelerômetro e câmera montados em óculos. Este trabalho concluiu que um sistema baseado exclusivamente em acelerômetro é adequado na identificação de atividades dinâmicas, enquanto a câmera é mais efetiva na identificação de atividades estáticas.

Outras pesquisas combinam acelerômetros com sensores RFID, que permitem conhecer o contexto do usuário. Por exemplo em Hong *et al.* (2008) e Hong *et al.* (2010) usaram um acelerômetro combinado com um sensor RFID para identificar tipos de objeto e desta maneira obter informação do contexto. Em Torres *et al.* (2013) usaram um acelerômetro e RFID para classificar movimentos realizados ao sair e entrar na cama. Em Shimokawara *et al.* (2013), usaram um

acelerômetro junto à tecnologia ZigBee. Com a intensidade do sinal recebido (*received signal strength indicator*, RSSI) estima-se a área na qual está o usuário e posteriormente os dados das acelerações permitem classificar a atividade realizada.

Outra combinação bastante usada no HAR consiste em incluir no sistema um acelerômetro e um sensor ECG. Em Jia e Liu (2013) e Li *et al.* (2010) são apresentados sistemas que classificam atividades ambulatoriais, enquanto em Tapia *et al.* (2007) são classificadas atividades físicas e suas intensidades com estes dois tipos de dispositivos.

Também se encontra na literatura trabalhos que misturam acelerômetros e giroscópios com sensores de temperatura e humidade como, por exemplo no trabalho de De *et al.* (2015), que aplicou esta combinação para classificar atividades ambulatoriais e da vida diária.

### 3 RECONHECIMENTO DE ATIVIDADES COM ACELERÔMETRO

As atividades humanas são irregulares e complexas. Cada pessoa realiza suas atividades no dia a dia de uma maneira particular, e no decorrer do dia, a mesma pessoa pode realizar as atividades de modo diferente.

Isto, somado a outros fatos, como o número de sensores corporais que um indivíduo usa confortavelmente, assim como os possíveis erros que podem se apresentar na toma de dados, devido a uma colocação errada dos sensores no corpo, sugerem alguns desafios no desenvolvimento de sistemas de HAR. Não obstante, os algoritmos de aprendizagem são uma ferramenta importante, que permite projetar um esquema de classificação de atividades com base em exemplos de treinamento.

Existem duas fases no reconhecimento de atividades: reconhecimento *Offline* e reconhecimento *Online*. Na fase *Offline* os dados dos sensores são coletados para cada atividade e os sinais são processados para ser usados no treinamento do algoritmo. Os processos aplicados iniciam com a filtragem das acelerações e a divisão em segmentos de tempo, conhecidos como janelas. Posteriormente, em cada janela são extraídas diferentes características dos sinais, denominados atributos. Em seguida estes atributos são normalizados para serem usados no treinamento e avaliação do algoritmo de classificação.

Na fase *Online* o modelo obtido no treinamento é utilizado para classificar novos dados em tempo real. Esta fase compreende alguns dos processos já mencionados: coleta de dados, filtragem, geração e normalização de atributos e finalmente a classificação das atividades. Como pode-se notar, o treinamento do algoritmo não está incluído nesta fase, por tratar-se de um processo complexo e demorado. Na sequência são explicados todos os processos mencionados.

### 3.1 COLETA DE DADOS

Como foi descrito na seção 0, os sistemas de HAR podem incluir diferentes tipos de sensores, com a finalidade de perceber o estado tanto do ambiente quanto dos usuários. Os sensores corporais fornecem uma metodologia adequada e de baixo custo, para monitorar pessoas em sua vida diária.


Um dos sensores corporais que mais fornece informação das atividades realizadas por uma pessoa, é o acelerômetro, pois responde tanto à frequência como à intensidade dos movimentos, podendo ser usado para medir inclinação ou movimento.

De igual maneira, em razão dos avanços no desenvolvimento dos MEMS, existem acelerômetros pequenos e de baixo custo, que permitem o projeto de sistemas leves, para monitorar pessoas sem atrapalhar seus movimentos, durante longos períodos de tempo.

#### 3.1.1 Características do acelerômetro

O acelerômetro é um dispositivo que obtém a aceleração de um objeto determinado através de um eixo específico. Existem vários tipos de transdutores usados para medir a aceleração, incluindo mecânicos, piezelétricos, piezoresistivos e capacitivos. Cada tipo de transdutor possui um mecanismo para medir a aceleração; porém, todos estão baseados no conceito da variação do sistema massa-mola, cujo é apresentado na Figura 4.

Figura 4: Sistema massa mola.



Fonte: Elaboração da própria autora.

Neste sistema, quando uma aceleração é aplicada para movimentar a massa ocorre um deslocamento sob o efeito de elasticidade da mola. Assim, a mola apresentará uma variação no seu comprimento, que pode ser calculada através da lei de Hooke, representada na Equação 1:

$$F = kx \quad (1)$$

Sendo  $k$  uma constante inerente à mola. No mesmo sistema, a segunda lei de Newton indica a relação existente entre a massa e a aceleração, através da Equação 2:

$$F = ma \quad (2)$$


Igualando as Equações 1 e 2, pode-se verificar que é possível calcular a aceleração da massa, conhecendo-se seu deslocamento, conforme apresentado nas Equações 3 e 4:

$$kx = ma \quad (3)$$

$$a = \frac{kx}{m} \quad (4)$$

O mesmo conceito pode ser estendido a dois ou três eixos. Assim, existem dispositivos que permitem medir a aceleração em um, dois ou três eixos simultaneamente, como se apresenta na Figura 5.

Figura 5 - Eixos do acelerômetro.



Fonte: Elaboração da própria autora.

A localização do acelerômetro em um corpo determina as magnitudes das acelerações geradas durante os movimentos. Uma medida comum para a saída proporcionada por um acelerômetro é o g, que representa o valor da gravidade na terra ( $1g = 9,8 \frac{m}{s^2}$ ). No Quadro 4 são apresentados valores de aceleração observados em diversas atividades.

Quadro 4 - Diferentes atividades e suas acelerações, dependendo da localização do acelerômetro no corpo humano.

<b>Atividade</b>	<b>Localização do Acelerômetro no corpo</b>	<b>Aceleração [g]</b>
Correr	Tornozelo	8 -12
	Costas	5
	Cabeça	4
Descer escadas	Tornozelo	8,1
Saltar em cama elástica	Tornozelo	7
Subir escadas	Tornozelo	7,4
Caminhar	Tornozelo	2,9 - 3,7

Fonte: Adaptada de Mathie *et al.* (2004).

A maioria das atividades humanas concentram a energia entre 0,3-3,5 Hz. Apesar de que as acelerações geradas quando o pé bate no chão podem alcançar frequências de até 60 Hz, aproximadamente 98% da energia da aceleração está contida abaixo dos 10 Hz e 99% abaixo dos 15 Hz. Durante a corrida apresentam-se frequências maiores, contudo, a maioria da energia está abaixo dos 18 Hz no tornozelo. As máximas frequências decrescem desde o tornozelo até a cabeça, e são maiores no eixo vertical comparadas com as dos eixos horizontais (MATHIE *et al.*, 2004).

Desta forma, pode-se concluir que um acelerômetro deve medir até  $\pm 12g$  em geral e até  $\pm 6g$  se localizado na cintura, para ser usado em avaliações de atividades físicas da vida diária. Em relação à frequência, deve-se operar entre 0-

20 Hz, que define a frequência de amostragem para o acelerômetro, com o objetivo de conseguir uma representação adequada dos movimentos do usuário (MATHIE *et al.*, 2004).

Além do tipo de sensor e sua localização no corpo, outros aspectos importantes para serem considerados no projeto de um sistema de HAR, baseado em sensores corporais, são a quantidade de sensores usados, o custo do sistema, e a facilidade de uso. Estas escolhas são feitas dependendo do propósito e a duração do monitoramento.

Para o monitoramento supervisionado de curta duração, podem ser usados vários sensores fixos no corpo, buscando coletar a maior quantidade de informação possível que permita avaliar os movimentos de maneira precisa.

Para o monitoramento não-supervisionado de longa duração, o usuário deve aceitar o sistema e usá-lo no seu dia a dia, por isso o sistema precisa ser confortável, fácil de usar e o mais imperceptível possível.

Uma abordagem simplificada, porém de eficiência demonstrada, consiste em usar um acelerômetro fixado em algum lugar do corpo. Esta opção diminui a complexidade no projeto do sistema, devido à redução da quantidade de informação gerada com os movimentos. Uma revisão na literatura feita em Mathie *et al.* (2004), indica que esta abordagem, usando um único acelerômetro próximo ao centro de massa do usuário, permite obter informações úteis.

### 3.2 FILTRAGEM DOS DADOS

Após a coleta dos dados, o passo seguinte é a filtragem do sinal. Nos sistemas HAR, geralmente são usados dois tipos de filtragem:

- Filtro de alta frequência, com o objetivo de eliminar ruído e minimizar os efeitos de erros aleatórios ocorridos durante a amostragem de dados;

- Filtro de baixa frequência, para separar a aceleração gravitacional, que corresponde a componente corrente contínua .

### 3.3 SEGMENTAÇÃO DE DADOS

As atividades humanas são realizadas durante períodos de tempo relativamente longos, se comparados com a taxa de amostragem do sensor. Uma amostra da aceleração não oferece informação importante da atividade realizada, por esta razão trabalha-se com um conjunto de amostras, pelo que após a filtragem, o sinal de aceleração é dividido em janelas de tempo de curta duração. Esta segmentação pode ser realizada aplicando algumas das técnicas descritas nos itens 0 - 0:

#### 3.3.1 Janela deslizante

Com as janelas deslizantes, o sinal de aceleração é dividido em frações de tempo de duração fixa. Na área de sistemas HAR, existem trabalhos prévios com diferentes durações das janelas, com valores entre 0,25s e 6,7s, como indicado em Preece *et al.* (2009), incluindo sobreposição entre janelas adjacentes. Esta técnica não precisa pré-processamento, sendo que é adequada para aplicações de tempo real. Devido a sua simplicidade e bons resultados é muito usada na classificação de atividades.

#### 3.3.2 Janela definida por eventos

Este método de segmentação necessita que o sinal de aceleração seja pré-processado para estabelecer eventos específicos como, por exemplo, o apoio do calcanhar ou o momento final de contato do pé no chão. Estes eventos são usados para definir as janelas. Nesta técnica, a duração das janelas não é fixa,

pois os eventos podem se apresentar de maneira não uniforme no tempo. Uma maneira de identificar eventos específicos pode ser, por exemplo, descobrir os momentos em que a componente ântero-posterior da aceleração do tronco muda de sinal.

### **3.3.3 Janela definida por atividades**

Nesta metodologia são identificados os momentos de troca de atividades, através das variações nas características de frequência do sinal. Estes instantes são usados para definir as janelas, cada uma das quais corresponde a uma atividade específica.

### **3.3.4 Janela definida por outros sensores e informação contextual.**

As janelas também podem ser definidas usando informações provenientes de outras fontes, como etiquetas RFID ou microfones.

## **3.4 GERAÇÃO DE ATRIBUTOS**

Depois da segmentação, comparar duas janelas com a finalidade de classificá-las é praticamente impossível, devido a que dois sinais quase nunca são exatamente iguais. Isso motiva a que em cada janela sejam extraídas medidas relevantes, com o objetivo de compará-las e desta forma caracterizar a postura e atividade realizada (LARA; LABRADOR, 2013). Estas propriedades, conhecidas como atributos, serão usadas como entradas do algoritmo de classificação. Existem diferentes tipos de atributos que podem ser usados no HAR, definidos nos itens 0-0 .

### **3.4.1 Atributos no domínio do tempo**

Os atributos no domínio do tempo são extraídos diretamente de cada janela e são grandezas estatísticas, como a média, a mediana, a variância, a obliquidade, a curtose, o intervalo interquartil, entre outros. Também podem ser usados os coeficientes de correlação entre diferentes eixos do acelerômetro.

### **3.4.2 Atributos no domínio da frequência.**

Estes atributos são extraídos da janela de dados, transformada ao domínio da frequência, através da Transformada de Fourier. Algumas atividades como, por exemplo andar de bicicleta, envolvem um movimento uniforme das pernas, com uma frequência dominante. Por outro lado, atividades com padrões de acelerações mais complexos como, por exemplo, correr, apresentarão vários componentes importantes de frequência.

### **3.4.3 Atributos heurísticos**

Este grupo de atributos abrange características derivadas a partir da análise dos sinais gerados pelos sensores, dependendo de movimentos ou posturas específicas, podendo-se mencionar o ângulo de orientação do sensor relativo à vertical, utilizado para diferenciar posturas estáticas; a velocidade angular, para identificar posturas e transições; a área debaixo da curva do sinal de aceleração filtrada (*signal magnitude área*, SMA), a aceleração pico a pico, o valor médio retificado e o valor eficaz, empregados geralmente para diferenciar atividades dinâmicas e estáticas.

### 3.4.4 Análise de Wavelet

A Transformada Discreta de Wavelet pode ser empregada para analisar características tanto no domínio do tempo como no domínio da frequência. Esta técnica produz dois conjuntos de coeficientes: os de aproximação e os de detalhe, que caracterizam o sinal em toda a janela de tempo e possuem dados em bandas específicas de frequência. A análise desta transformada tem sido empregada em três tipos de problema dentro do reconhecimento de atividades: realce dos sinais, identificação de pontos de troca de frequência e geração de atributos no domínio tempo-frequência.

O realce dos sinais permite focar em bandas de frequência de interesse, o que pode ser utilizado para eliminar o ruído de alta frequência ou *drift* (Propagação de erro na medição) de baixa frequência. A identificação de pontos de troca de frequência, que permite reconhecer, por exemplo diferentes tipos de marcha. Os atributos de tempo-frequência são geralmente obtidos calculando uma ou mais grandezas estatísticas a partir dos coeficientes de aproximação e de detalhe. Podem ser, por exemplo a soma dos quadrados dos coeficientes, o valor quadrático médio, ou o desvio padrão.

De acordo com Preece *et al.* (2009), vários estudos compararam o desempenho dos atributos obtidos a partir da Transformada de Wavelet, com os atributos no domínio do tempo e da frequência. Estes apresentam um melhor desempenho, o que sugere que, apesar da transformada Wavelet ser empregada na análise de sinais não-estacionárias, pode não ser o método mais adequado para caracterizar janelas de curta duração que possuem pouca variação em frequência.

### 3.5 NORMALIZAÇÃO

Após a geração dos atributos que são usados como as entradas do algoritmo de classificação, é importante que todos estejam na mesma escala, para evitar a existência de atributos dominantes e permitir ao algoritmo convergir rapidamente. Para isso é recomendável ajustá-los aplicando alguma técnica de normalização.

### 3.6 SELEÇÃO DE ATRIBUTOS

Geralmente, nos problemas de classificação de atividades, tem-se um conjunto grande de atributos e não existe uma maneira simples de identificar quais são os atributos mais apropriados para diferenciar atividades com base em determinados algoritmos. De forma geral, um bom conjunto de atributos possui as seguintes características:

- Apresenta variações pequenas nos mesmos movimentos;
- Exibe variações consideráveis entre diferentes atividades.

Na escolha dos atributos, é importante minimizar a redundância, para evitar o aumento da complexidade desnecessária nos algoritmos, assim como uma possível diminuição da exatidão na classificação. A escolha dos atributos pode ser realizada das seguintes maneiras:

- Com a avaliação visual e estatística da distribuição de um atributo para as diferentes atividades. Serão escolhidos conjuntos de atributos que mudam de maneira marcante e apresentam pouca sobreposição entre atividades;
- Também pode-se analisar a correlação entre os atributos, para selecionar aqueles que apresentam alta correlação nas mesmas atividades e baixa entre diferentes atividades;
- Outra técnica que pode ser aplicada é adicionar e remover atributos sequencialmente, analisando o desempenho do classificador;

- Aplicar métodos para reduzir a dimensão dos dados, tais como o *Principal Component Analysis* (PCA). Este método combina a essência de todos os atributos, procurando uma projeção que transforme o conjunto original em outro conjunto de menor dimensão, preservando a maioria da informação dos dados originários.

## 4 SIRAH: SISTEMA DE RECONHECIMENTO DE ATIVIDADES HUMANAS

Nesta seção apresenta-se o Sistema de Reconhecimento de Atividades Humanas, denominado SIRAH. Para o início do desenvolvimento do sistema foram analisadas as atividades e posturas a serem identificadas, tipo de sensor a ser usado e sua localização.

### 4.1 ATIVIDADES A SEREM IDENTIFICADAS

Pretende-se identificar três posturas: em pé, sentado e deitado, e quatro atividades globais/ambulatórias: sentar-se, levantar-se, correr e caminhar. Estas atividades e posturas foram escolhidas porque fornecem informação relevante do estado de saúde geral de uma pessoa e são básicas para poder viver de maneira independente.


### 4.2 TIPO DE SENSOR

Nesta pesquisa projetou-se um primeiro protótipo do SIRAH, baseado no acelerômetro MEMS MMA7455L fabricado pela *Freescale Semiconductor*. Trata-se de um acelerômetro de três eixos com saída digital, que pode se comunicar com um microcontrolador usando os protocolos I2C (*Inter-Integrated Circuit*) ou SPI (*Serial Peripheral Interface*). Possui três sensibilidades selecionáveis:  $\pm 2g$ ,  $\pm 4g$  e  $\pm 8g$ .

O sensor é um circuito integrado (CI) de superfície micromecânica, constituído por uma célula sensível capacitiva e um condicionador de sinais ASIC (*Application Specific Integrated Circuits*) contidos em um mesmo encapsulamento. O dispositivo pode ser modelado como uma placa ligada a uma massa central móvel, entre as placas fixas, cujo modelo físico é apresentado na Figura 6. A placa

móvel pode-se deslocar de sua posição de repouso se o sistema é submetido a alguma aceleração.

Figura 6 - Modelo físico simplificado do transdutor.



Fonte: Adaptada de Freescale Semiconductor (2007).

As placas formam dois blocos de capacitores e quando a placa central se desloca com a aceleração, a distância entre ela e as placas fixas aumentará de um lado e diminuirá do outro, na mesma proporção, alterando assim a capacitância de cada capacitor. Dessa forma pode-se verificar que a mudança na distância é uma medida da aceleração.

O CI que contém o acelerômetro utiliza técnicas de capacitores chaveados para medir as capacitâncias e extrair assim, os dados de aceleração, a partir da diferença entre os dois capacitores. O CI também condiciona e filtra o sinal, proporcionando uma saída digital proporcional à aceleração submetida (FREESCALE SEMICONDUCTOR, 2007).

#### 4.3 LOCALIZAÇÃO DO SENSOR

No projeto do SIRAH escolheu-se instalar o acelerômetro na cintura do usuário pois é uma localização central e adequada para as atividades e posturas a serem reconhecidas. Esta posição permite usar o sistema com comodidade e conforto, sem atrapalhar os movimentos. O protótipo e o local de instalação podem ser observados na Figura 7.

Figura 7 - Sistema SIRAH desenvolvido e o posicionamento no indivíduo.




Fonte: Elaboração da própria autora.

#### 4.4 ELEMENTOS DE HARDWARE E SOFTWARE

Os dispositivos eletrônicos que compõem o hardware do SIRAH são um microcontrolador, dois transceptores Zigbee, uma memória SD, o acelerômetro MMA7455L e um computador apresentados na Figura 8.

Figura 8 - Hardware do SIRAH




Fonte: Elaboração da própria autora.

O microcontrolador usado é o ATmega328 com SRAM de 2 KB e uma EEPROM de 1 KB, incluído em uma placa de ARDUINO UNO. O sistema utiliza o protocolo Zigbee para controlar a calibração do acelerômetro e a coleta de dados. Os módulos utilizados são XBee 1mW Trace Antenna – S1. Devido à grande quantidade de dados gerados pelo acelerômetro, as acelerações dos três eixos não podem ser armazenadas na memória do ATmega 328, motivo pelo qual utilizou-se um módulo de memória SD.

A comunicação entre o Acelerômetro e o microcontrolador é realizada através do protocolo I2C, e entre o microcontrolador e a memória SD a través do protocolo SPI. A programação do microcontrolador foi realizada usando o *software* livre para o Arduino.

Pela construção física do protótipo e a localização no usuário, os eixos X, Y e Z do acelerômetro ficam no corpo com a configuração mostrada na Figura 9:

Figura 9 - Eixos do acelerômetro no corpo do usuário.



Fonte: Elaboração da própria autora.

No projeto do SIRAH, foram desenvolvidas as duas fases do reconhecimento de atividades. A primeira, reconhecimento *Offline*, teve como objetivo a escolha dos atributos e o treinamento e avaliação do algoritmo de classificação. A segunda, reconhecimento *Online*, teve como finalidade implementar o modelo de classificação previamente treinado para realizar a classificação em tempo real de dados novos. Estas duas abordagens serão detalhadas nas seções 0 e 0.

## 4.5 FASE OFFLINE

Os sensores utilizados no HAR geram grandes quantidades de dados com características únicas, o que torna a análise manual em uma tarefa de difícil execução. Por esta razão, são utilizados diversos modelos com a finalidade de caracterizar, reduzir e classifica-los.

O reconhecimento das atividades humanas é realizado aplicando algoritmos de classificação, que fazem a correspondência entre pontos de entrada com etiquetas de classes previamente definidas. No HAR aplicou-se desde esquemas baseados em umbrais, até os mais avançados como as redes neurais, incluindo clusterização, modelos de Markov e rede Bayesiana, entre outros.

As técnicas de classificação estão agrupadas na área de aprendizado automático. Os algoritmos de aprendizado automático aprendem da experiência disponível, generalizando comportamentos a partir das informações recebidas. Esta experiência poder ser indireta, por reforço ou direta. Partindo dessa premissa, os algoritmos são conhecidos como de aprendizagem não-supervisionada, por reforço ou supervisionada, respectivamente.

No primeiro caso, o algoritmo aprende padrões de entrada apesar de não existir nenhuma retroalimentação explícita. A principal técnica não-supervisionada é o agrupamento, que detecta grupos de pontos similares.

Na aprendizagem por reforço o algoritmo instrui-se a partir de uma série de interações que podem ser recompensas ou castigos (penalidades).

Finalmente, na aprendizagem supervisionada, o algoritmo recebe pares de entradas-saídas, e aprende uma função que mapeia uma entrada em uma saída (RUSSELL; NORVIG, 2009). A escolha do algoritmo é feita dependendo do tipo de dados, os valores das etiquetas (valores discretos ou contínuos) entre outras características. No HAR são usados algoritmos principalmente supervisionados, pois as saídas desejadas são controladas.

No desenvolvimento de SIRAH foram estudados os algoritmos de regressão linear, árvores de decisão, máquinas de suporte vetorial e redes neurais artificiais. Escolheu-se o modelo das redes neurais artificiais, RNA, de múltiplas camadas, amplamente usado no reconhecimento de atividades, devido aos bons resultados que apresenta (LUBINA; RUDZKI, 2015), (CHEN; XUE, 2015), (DA SILVA; GALEAZZO, 2013), (WANG *et al.*, 2012), (PREECE *et al.*, 2009), (BAEK *et al.*, 2004).

Apresenta-se na Figura 10 o conjunto de processos necessários para preparar as entradas da RNA, que são detalhados nas seções 0-0.

Figura 10 - Processos da fase *Offline* do SIRAH.



Fonte: Elaboração da própria autora.

#### 4.5.1 Coleta de dados com o sensor MMA7455L

Devido à posição central no corpo, o acelerômetro deve trabalhar na faixa de  $\pm 6g$ , como indicado anteriormente, pelo que foi selecionada a sensibilidade de  $\pm 8g$  com resolução de 10 bits.

Em relação à frequência dos movimentos humanos, o acelerômetro deve medir frequências entre 0-20 HZ. Pelo teorema de *Nyquist*, a frequência de


amostragem deve ser no mínimo o dobro da máxima frequência do sinal. Desta maneira, a frequência de amostragem definida foi de 40 Hz, valor próximo à taxa de amostragem do trabalho de Mathie *et al.* (2004) com uma frequência de 45 Hz, e superior à dos trabalhos de Maurer *et al.* (2006), com 30 HZ e de Baek *et al.* (2004) com 15 HZ.

Na atualidade existem duas abordagens em relação à flexibilidade de um sistema HAR. A primeira indica que cada sistema deve ser específico para cada pessoa, devido à variabilidade das posturas e atividades entre as pessoas. Desta maneira, o treinamento do algoritmo de aprendizado dever ser realizado com dados de um único usuário. A segunda abordagem indica que não é viável treinar um algoritmo para cada usuário; sendo assim, os sistemas HAR devem ser projetados para que funcionem com diferentes usuários.

O sistema SIRAH foi projetado com base na primeira abordagem. Um sistema customizado para um usuário sempre obterá uma maior precisão ao ser comparado com um sistema geral. Assim, os dados formam armazenados durante 6 minutos na memória SD, enquanto um usuário de 37 anos assumia cada postura e realizava as diferentes atividades.

Nas figuras 11, 12 e 13 são apresentados os sinais das acelerações geradas pelo sensor nas diferentes posturas durante um segundo de medição. Nas posturas o movimento do corpo é mínimo sendo que os valores das acelerações permanecem constantes durante todo o tempo da medição.

Figura 11 - Acelerações geradas na postura ereta.




Fonte: Elaboração da própria autora.

Os sinais do sensor estão formados pela aceleração gravitacional devida à postura do usuário e à aceleração devida ao movimento dele. Na postura ereta a aceleração gravitacional é detectada no eixo Y, como pode-se notar na Figura 11, com um valor de aproximadamente  $-1g$ . Os valores dos eixos X e Z são aproximadamente iguais a  $0g$  e  $-0,2g$  respectivamente. O sinal positivo ou negativo está dado pela orientação do sensor no protótipo SIRAH, como foi apresentado na Figura 9 da página 58.

Na Figura 12 são apresentados os sinais gerados pelo acelerômetro quando o usuário assume a postura sentada. Observa-se que as acelerações também permanecem constantes. Nos eixos Y e Z os valores estão determinados pela inclinação adquirida pelo corpo do usuário e no eixo X o valor é  $0g$  pois não está inclinado nessa direção.

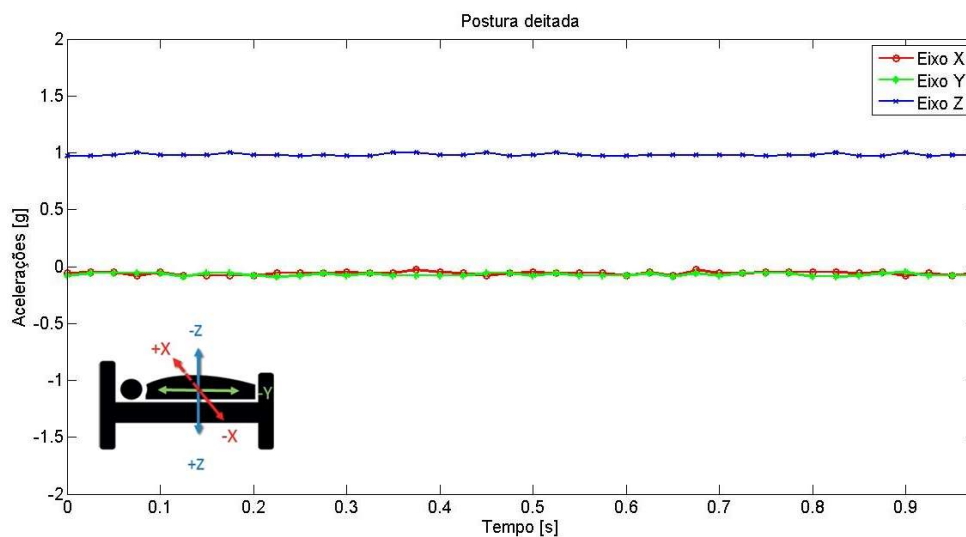
Figura 12 – Acelerações geradas na postura sentada.



Fonte: Elaboração da própria autora.

Na Figura 13 ilustra-se as acelerações entregadas pelo acelerômetro na postura deitada. Nesta postura a aceleração da gravidade é registrada no eixo Z e os valores nos eixos X e Y são iguais a 0g.

Figura 13 - Acelerações geradas na postura deitada.

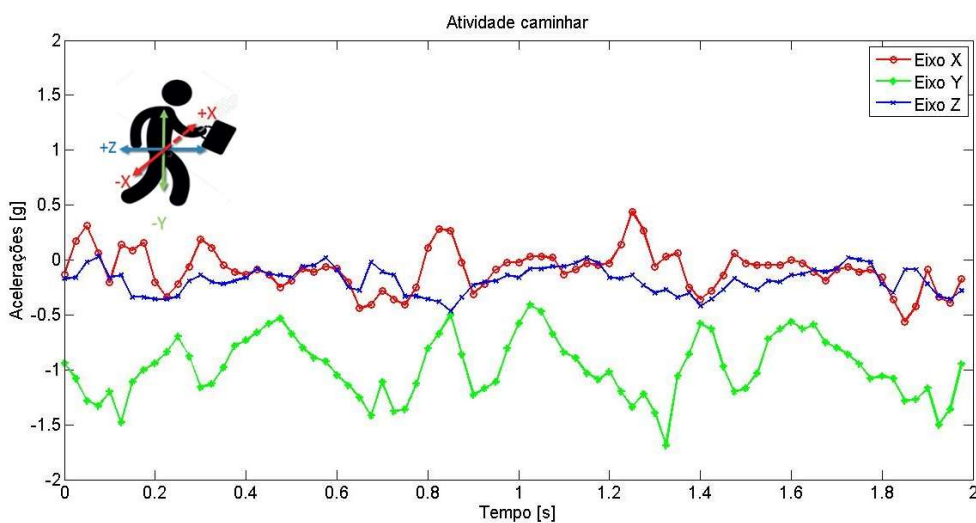


Fonte: Elaboração da própria autora.

Nas figuras 14, 15 e 16 são apresentados os sinais das acelerações geradas pelo sensor nas diferentes atividades durante dois segundos de medição.

Na Figura 14 é notado a variação dos sinais nos três eixos na atividade caminhar. Nos eixos X e Z os sinais variam em torno de 0g e no eixo Y o sinal varia em torno de -1g, valores observados na postura ereta.

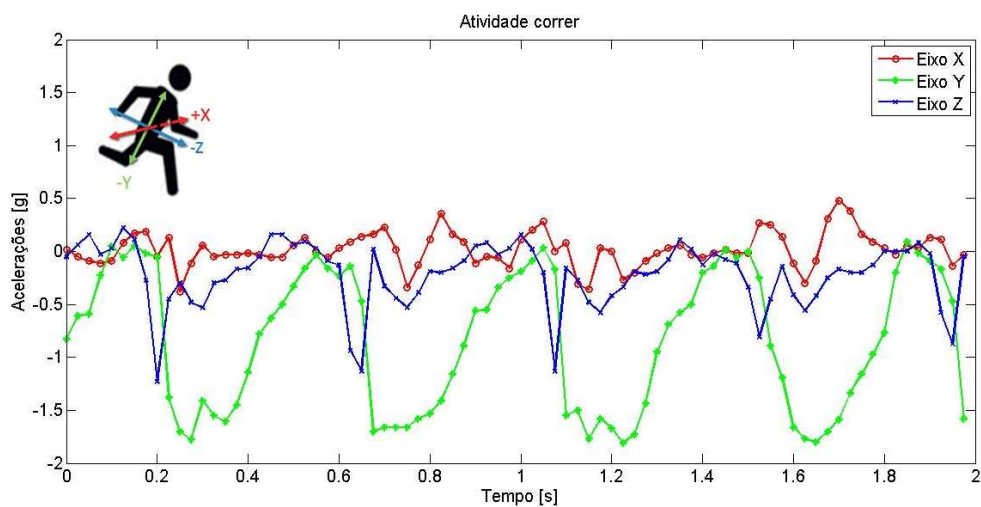
Figura 14 - Acelerações geradas na atividade caminhar.



Fonte: Elaboração da própria autora.

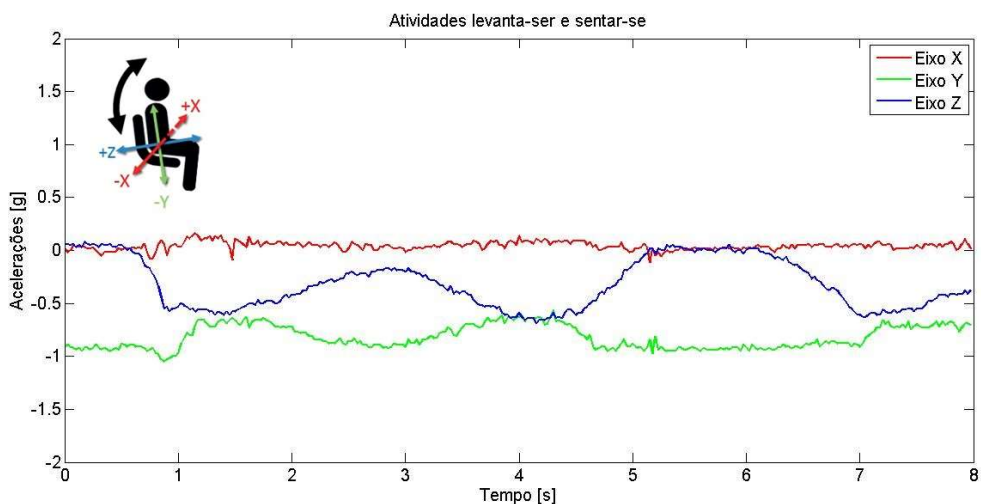
Na Figura 15 ilustra-se a atividade correr, que apresenta variações mais rápidas e de maior amplitude quando comparada com a atividade caminhar na Figura 14. Pode-se observar claramente um padrão nos sinais determinado pelos momentos em que o calcanhar entra em contato com o chão.

Figura 15 - Acelerações geradas na atividade correr.



Fonte: Elaboração da própria autora.

Figura 16 - Acelerações geradas nas atividades levantar e sentar.




Fonte: Elaboração da própria autora.

Na Figura 16 apresentam-se as atividades sentar-se e levantar-se, que são de curta duração e foram coletadas de maneira contínua, sendo preciso separá-las para obter os exemplos de treinamento de cada uma. Esta separação poderia ser feita de maneira manual, que além de tedioso poderia introduzir erros não

desejados. Por isso foi desenvolvido um procedimento empírico que separar as atividades automaticamente, cuja explicação é descrita a seguir.

Os sinais dos eixos Y e Z, por serem os que mais mudam nestas atividades, são multiplicados ponto a ponto e filtrados. O sinal resultante apresentado na Figura 17, possui alguns picos facilmente identificáveis, que correspondem à transição entre as posturas sentada e ereta. Tais transições identificam as atividades sentar-se e levantar-se.

Figura 17 - Multiplicação dos eixos Y e Z.




Fonte: Elaboração da própria autora.

Identificados os picos no sinal resultante o intervalo entre um pico e o seguinte foi dividido pela metade. Este passo é apresentado na Figura 18. Nesta mesma figura, nota-se que as acelerações dos eixos Y e Z das posturas sentada e ereta representam o início e o fim das atividades sentar-se e levantar-se.

Em cada intervalo, são encontrados também os mínimos. Se o mínimo estiver antes do pico, então a atividade é levantar-se. Si pelo contrário, o valor mínimo estiver localizado depois do pico então a atividade é sentar-se.

Figura 18 - Picos identificados e atividades levantar e sentar separadas.

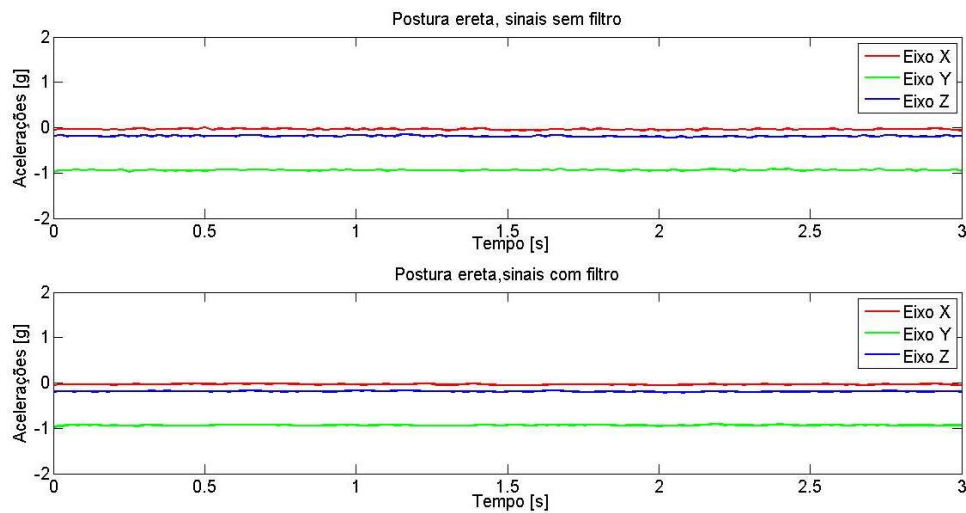


Fonte: Elaboração da própria autora.

#### 4.5.2 Filtro

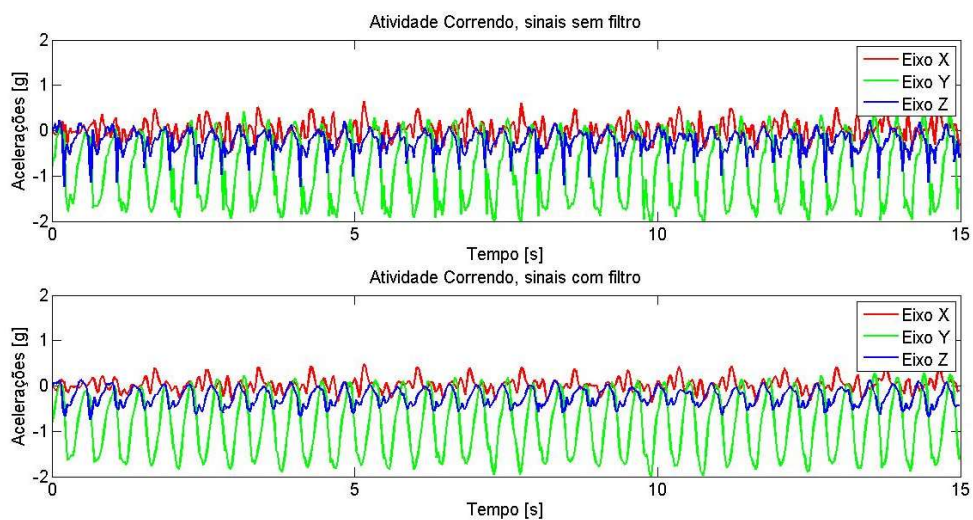
Após obter os dados das posturas e atividades, a etapa seguinte consiste em filtrar os sinais de aceleração. A filtragem de alta frequência foi realizada aplicando um passa-baixas de média móvel com três coeficientes. Dois exemplos dos sinais resultantes desta etapa, com a postura ereta e a atividade correr, são apresentados na Figura 19 e na Figura 20, respectivamente. Como pode-se observar, a diferença entre os sinais sem e com filtro na postura não é muito evidente, pois as mudanças através do tempo são poucas. Pelo contrário, na atividade correr pode-se observar como os sinais são suavizados pelo filtro.

Figura 19 - Filtro passa-baixas, postura ereta.



Fonte: Elaboração da própria autora.

Figura 20 - Filtro passa-baixas, atividade correr.



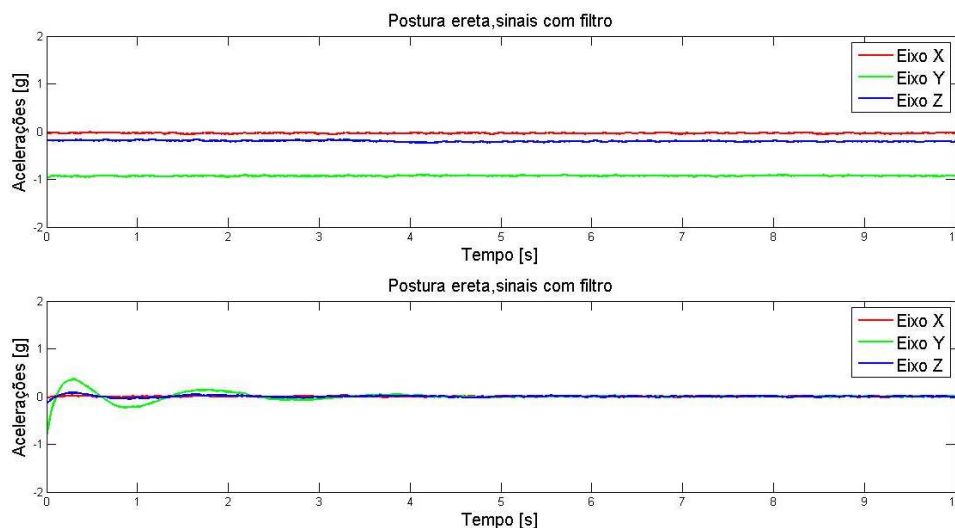
Fonte: Elaboração da própria autora.

O filtro de baixa frequência foi estudado na pesquisa, mas não foi utilizado no sistema SIRAH, pois este filtro separa a componente gravitacional dos sinais

de aceleração, característica que diferencia as posturas entre elas. Se, por exemplo, a postura ereta é filtrada com um passa-altas, as acelerações dos três eixos serão iguais a 0g, como se pode observar na Figura 21. Se o filtro é aplicado nas outras posturas as três teriam todos os eixos X, Y e Z iguais a 0g, perdendo as características que permitem diferenciá-las.

Este tipo de filtro é aplicado nos sistemas que fazem uma pre-classificação, para diferenciar entre posturas e atividades, e posteriormente, classificam a postura ou atividade específica. Um exemplo deste processo é apresentado no trabalho de da Silva e Galeazzo (2013). Como não é este o objetivo da pesquisa, este tipo de filtro não foi utilizado no sistema SIRAH.

Figura 21 - Filtro passa-altas, postura ereta.



Fonte: Elaboração da própria autora.

### 4.5.3 Segmentação

Nesta etapa optou-se por dividir os dados do sensor em janelas fixas de tempo, devido a que esta abordagem não requer nenhum pré-processamento adicional e possibilita alcançar bons resultados. Não obstante, não existe um

consenso em relação à duração apropriada para cada problema. De fato, o tamanho da janela é um problema específico dos sistemas HAR. Quanto maior o tamanho da janela, todos os processos do sistema serão aplicados com menor frequência, reduzindo-se a carga computacional. Porém, isto poderia ocasionar a perda de precisão na classificação realizada pelo sistema. Por isso deve-se procurar um equilíbrio entre a precisão e complexidade computacional do sistema.

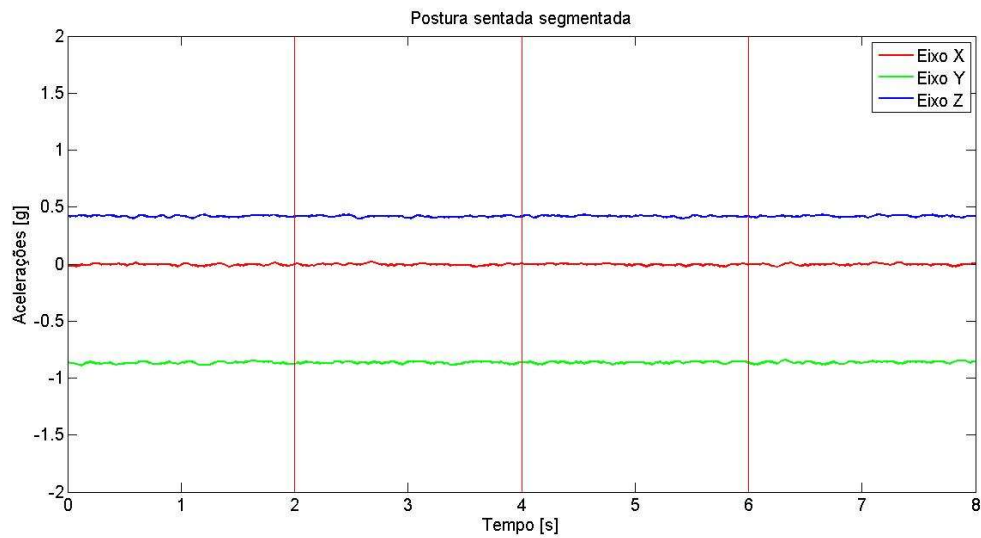
Preece *et al.* (2009) reportaram no seu trabalho o uso de janelas com um intervalo de valores entre 0,25s e 6,7s. Bulling, Blanke e Schiele (2014) realizaram uma avaliação do desempenho do sistema HAR com diferentes tamanhos de janela (0,1s, 0,25s, 0,5s, 1s, 2s, 3s, 4s, 5s, 6s, 7s e 8s). De acordo com os autores o melhor desempenho foi obtido com uma duração igual a 1s.

A janela selecionada para segmentar os dados no sistema SIRAH é de 2s sem sobreposição. Este tamanho de janela foi escolhido por ser um valor médio entre os diferentes valores observados na literatura, tentando manter um equilíbrio entre complexidade e precisão do sistema. Também foram tomados em conta trabalhos prévios com o de Shoib *et al.* (2013) e Preece *et al.* (2009), onde indicaram que esta é uma duração suficiente que permite o reconhecimento de atividades de forma razoável.

Tomando os 6 minutos (360 segundos) de dados armazenados para cada postura e atividade, divididos em janelas de 2s de duração, têm-se 180 vezes 7, igual a 1.260 segmentos para serem processados.

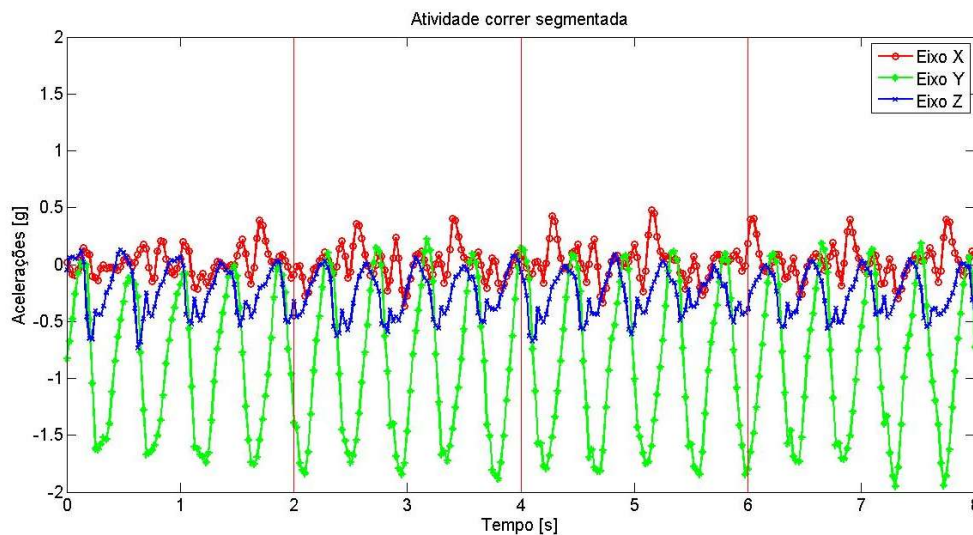
Um exemplo de segmentação realizada na postura sentada é apresentado na Figura 22. Como pode-se observar, os sinais permanecem relativamente constantes em toda a janela de tempo. O resultado para as outras posturas é similar ao apresentado na Figura 22. Em relação às atividades, na Figura 23 é apresentado este processo de divisão para a atividade correr. Diferente da postura sentada, a atividade correr apresenta variações na amplitude em cada janela.

Figura 22 - Postura sentada segmentada com janela de 2s.



Fonte: Elaboração da própria autora.

Figura 23 - Atividade correr segmentada com janela de 2s.




Fonte: Elaboração própria autora.

Na Figura 24 é apresentada a segmentação realizada para as atividades sentar-se e levantar-se. Neste caso, cada pico encontrado no processo de

separação de atividades foi considerado como centro da janela, sendo que alguns dados não são usados, como se observa na Figura 24.

Figura 24 - Atividades levantar-se e sentar-se segmentadas



Fonte: Elaboração da própria autora

#### 4.5.4 Geração de atributos

Como foi mencionado na seção 0, existem vários atributos ou características, que uma vez extraídos de cada janela, permitem diferenciar as posturas e atividades. Neste trabalho foram gerados atributos no domínio do tempo, da frequência e um heurístico, apresentados nos Quadros 5 e 6. O atributo heurístico é *Signal Magnitude Área*, SMA, que é calculada diretamente na janela de tempo, sendo assim incluído no quadro de atributos no domínio do tempo.

Quadro 5 - Atributos extraídos no domínio do tempo.

Atributo	Definição	Equação aplicada	Total de atributos em cada janela
<b>Média</b>	Valor médio aritmético dos valores das acelerações na janela.	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$	$\bar{x}$ $\bar{y}$ $\bar{z}$
<b>Desvio padrão</b>	Medida da dispersão dos dados; mostra o quanto de variação ou "dispersão" existe em relação à média.	$s = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}$	$s_x$ $s_y$ $s_z$
<b>Variância</b>	Medida da dispersão estatística, que indica quão longe se encontram seus valores do valor esperado.	$s^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$	$s_x^2$ $s_y^2$ $s_z^2$
<b>Variação</b>	Diferença entre o valor máximo e mínimo dos dados na janela.	$var(x) = \max_i x_i - \min_i x_i$	$var(x)$ $var(y)$ $var(z)$
<b>Assimetria</b>	Grau de afastamento de uma distribuição da unidade de assimetria. Uma Distribuição é Simétrica quando media=mediana=moda.	$S(x) = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^{\frac{3}{2}}}$	$S(x)$ $S(y)$ $S(z)$
<b>Curtose</b>	Grau de achatamento da distribuição dos dados na janela;	$k(x) = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^2}$	$k(x)$ $k(y)$ $k(z)$
<b>Correlação</b>	Medida da relação entre duas variáveis. Neste caso este valor foi achado para cada	$\rho(x, y) = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}}$	$\rho(x, y)$ $\rho(x, z)$ $\rho(y, z)$

	par de eixos;		
<b>Excentricidade</b>	Calcula três eigenvalores da matriz de covariância. A magnitude dos eigenvalores indica a variação dos dados.	$C = \begin{bmatrix} cov(x,x) & cov(x,y) & cov(x,z) \\ cov(y,x) & cov(y,y) & cov(y,z) \\ cov(z,x) & cov(z,y) & cov(z,z) \end{bmatrix}$	$\lambda_1$ $\lambda_2$ $\lambda_3$
<b>Signal Magnitude Área</b>	Medida estatística da magnitude de uma quantidade variável.	$SMA(x,y,z) = \sum_{i=1}^N ( x_i  +  y_i  +  z_i )$	$SMA(x,y,z)$

Fonte: Elaboração da própria autora.

Quadro 6 - Atributos extraídos no domínio da frequência

<b>Atributo</b>	<b>Definição</b>	<b>Equação aplicada</b>	<b>Total atributos em cada janela</b>
<b>Energia média</b>	Somatória dos coeficientes da FFT.	$E(X) = \sum_{k=1}^m X(k)$	$E(X)$ $E(Y)$ $E(Z)$
<b>Entropia espectral</b>	A entropia espectral mensura a irregularidade, complexidade ou a quantidade de desordem do sinal estudado.	$H(X) = - \sum_{k=1}^m X(k) \log(X(k))$	$H(X)$ $H(Y)$ $H(Z)$
<b>Magnitude máxima</b>	Coefficiente com máxima magnitude.	$M(X) = \max_i ( X(k_i) )$	$M(X)$ $M(Y)$ $M(Z)$

Fonte: Elaboração da própria autora.

No total têm-se 34 atributos disponíveis para o treinamento e avaliação da RNA.

#### 4.5.5 Normalização

Antes de serem apresentados como entradas da RNA, os atributos foram normalizados, devido a que possuem diferentes escalas e dispersões. No trabalho foi usada a normalização indicada na Equação 5:

$$x_j = \frac{x_j - \mu}{\delta} \quad (5)$$

Sendo que  $\mu$  é o valor médio e  $\delta$  é o desvio padrão dos atributos. Este procedimento é conhecido como escalonamento e também é usado em outros algoritmos. Após esta normalização todos os atributos têm uma média nula e uma variância unitária.

#### 4.5.6 Seleção dos atributos

A escolha dos atributos pode ser manual ou automática. Para treinar a RNA do sistema SIRAH, a escolha foi realizada das duas formas. Manual, escolhendo conjuntos de atributos aplicados em trabalhos anteriores e automática, aplicando o método PCA:

1. Selecionaram-se os atributos usados no trabalho de Baek *et al.* (2004) com o objetivo de comparar a precisão do sistema SIRAH com o apresentado no trabalho mencionado;
2. Escolheram-se os atributos de da Silva e Galeazzo (2013) para avaliar o impacto do aumento do número de atributos no desempenho da classificação;

3. Aplicou-se o método, PCA no conjunto apresentado por da Silva e Galeazzo (2013) com o objetivo de escolher atributos automaticamente e tentar melhorar o desempenho do classificador.

#### **4.5.6.1 PCA Principal Component Analysis**

O conceito de PCA foi proposto, originalmente, por Pearson (1901). Supondo que os atributos são vetores de dados descritos por  $n$  dimensões, PCA é um método de redução, que tenta mapear esses atributos originais em um espaço de menor dimensão  $k$ , o que resulta em uma redução da dimensão original (WANG *et al.*, 2005). A característica principal da PCA é que combina a essência de todos os atributos, procurando uma projeção que transforme o conjunto dos atributos originais em outro conjunto com uma dimensão menor e que preserve a maioria da informação dos dados originários (HAN; KAMBER, 2006).

O procedimento para determinar a PCA é descrito a seguir:

1. Os dados de entrada são normalizados aplicando a Equação (5). Desse modo todos os atributos cairão no mesmo intervalo, o que ajuda a garantir que atributos com grande amplitude não dominarão os atributos com uma amplitude menor;
2. Calculam-se  $k$  vetores ortonormais que fornecem uma base para os dados de entrada normalizados. Estes vetores são unitários e apontam, cada um, na direção perpendicular aos outros. São conhecidos como os componentes principais. Os dados de entrada são combinações lineares dos componentes principais;
3. Os componentes principais são organizados em ordem decrescente. Os componentes principais servem como os novos eixos para os dados, oferecendo informação importante sobre a variância. Nos eixos organizados, o primeiro apresenta a maior variância entre os dados, o segundo apresenta a seguinte maior variância, e assim sucessivamente;

4. Como os componentes são organizados decrescentemente, o tamanho dos dados pode ser reduzido eliminando-se os componentes mais fracos, que são aqueles com menor variância. Usando os componentes mais fortes, será possível reconstruir uma boa aproximação dos dados originais.

A PCA é de baixo custo computacional. Pode ser aplicado a dados ordenados e desordenados e pode tratar dados dispersos e assimétricos. Dados de mais de duas dimensões podem ser tratados reduzindo o problema a duas dimensões (HAN; KAMBER, 2006).

No Quadro 7 são resumidos os conjuntos de atributos que foram usados para o treinamento da RNA.

Quadro 7- Estudos de caso realizados com diferentes atributos

<b>Estudo de caso</b>	<b>Atributos</b>
<b>Primeiro</b>	Média aritmética, desvio padrão, assimetria, curtose e excentricidade;
<b>Segundo</b>	Média aritmética, SMA, desvio padrão, assimetria, curtose, correlação, variação, energia média, entropia, espectral e magnitude máxima.
<b>Terceiro</b>	Conjunto base do Segundo estudo de caso, aplicando a PCA para diminuir a dimensão.

Fonte: Elaboração da própria autora.

Um exemplo do conjunto usado no primeiro estudo de caso é apresentado na Tabela 1, formado pela média aritmética ( $\bar{x}$ ,  $\bar{y}$ ,  $\bar{z}$ ), desvio padrão ( $s_x$ ,  $s_y$ ,  $s_z$ ), assimetria ( $s(x)$ ,  $s(y)$ ,  $s(z)$ ), curtose ( $k(x)$ ,  $k(y)$ ,  $k(z)$ ) e excentricidade ( $\lambda_1$ ,  $\lambda_2$ ,  $\lambda_3$ ) dos três eixos. Os exemplos usados nos outros dois testes possuem a mesma forma da Tabela 2, incluindo uma maior quantidade de atributos.

Tabela 1 - Exemplo de conjunto usado no primeiro estudo de caso


Exemplo	$\bar{x}$	$\bar{y}$	$\bar{z}$	$s_x$	$s_y$	$s_z$	$S(x)$	$S(y)$	$S(z)$	$k(x)$	$k(y)$	$k(z)$	$\lambda_1$	$\lambda_3$	$\lambda_3$
#1	0,4	-0,6	-0,4	-0,8	-0,7	-1,1	0,2	1,2	-0,6	-0,3	0,5	-0,2	-0,7	-0,6	0,2

Fonte: Elaboração da própria autora.

#### 4.5.7 Treinamento da rede neural artificial

Uma RNA é um modelo que tenta imitar a estrutura biológica cerebral. É composta por várias unidades de processamento interligadas entre si, que visam o armazenamento a disponibilização de conhecimento adquirido durante a aprendizagem no ambiente em que está inserida (Haykin, Redes Neurais: Princípios e prática, 2001). A unidade básica da rede, chamada neurônio, é apresentada na Figura 25.

Figura 25 - Modelo básico do neurônio.



Fonte: Elaboração da própria autora.

Na Figura 25 podem-se observar os elementos básicos da unidade de processamento, sendo:

- $\theta_i$  os pesos do modelo;
- Sinapses, pontos de conexão, cada um com um peso característico;

- Somador, que realiza a operação com todas as entradas ponderadas por seu respectivo peso;
  - Função de ativação, que restringe o intervalo permissível da amplitude da saída do neurônio. A função de ativação usada neste trabalho é a sigmoide  $g(a) = \frac{1}{1 + e^{-a}}$ . Seu valor está entre  $0 \leq g(a) \leq 1$  e foi escolhida pois permite introduzir não-linearidades no modelo, o que permite a construção de hipóteses complexas não lineares;
- O bias  $x_0$ , unidade cuja função é o controle do nível de saída do neurônio; sempre possui um valor igual a um.


Matematicamente o neurônio é uma unidade logística, que aceita as entradas  $a = (x_0\theta_0 + x_1\theta_1 + x_2\theta_2 + \dots + x_n\theta_n)$  e fornece uma saída dada pela Equação 6:

$$h_\theta(x) = g(a) \tag{6}$$

Neste trabalho escolheu-se uma RNA perceptron multicamadas, que é um grupo de neurônios conectados conforme apresentado na Figura 26.

Nesta RNA, têm-se três camadas: a camada de entrada; a camada escondida que recebe esse nome pois seus valores não são observados nos pares de entrada-saída usados para o treinamento e, finalmente, a camada de saída.

Figura 26 - RNA perceptron multicamadas



Fonte: Elaboração da própria autora.

O cálculo da saída de cada unidade é obtido pela Equação 7:

$$a_1^{(2)} = g\left(\theta_{10}^{(1)} x_0 + \theta_{11}^{(1)} x_1 + \theta_{12}^{(1)} x_2 + \theta_{13}^{(1)} x_3 + \dots + \theta_{1n}^{(1)} x_n\right) \quad (7)$$

Sendo  $a_1^{(2)}$  o valor calculado na unidade 1 da camada 2. O mesmo cálculo é realizado para outras unidades. A saída total da rede é dada pela Equação 8:

$$h_{\theta}(x) = a_1^{(3)} = g\left(\theta_{10}^{(2)} a_0^{(2)} + \theta_{11}^{(2)} a_1^{(2)} + \theta_{12}^{(2)} a_2^{(2)} + \theta_{13}^{(2)} a_3^{(2)} + \dots + \theta_{1n}^{(2)} a_n^{(2)}\right) \quad (8)$$

Este processo para calcular  $h_{\theta}(x)$  é conhecido como *forward propagation*, devido a que o procedimento acontece desde a entrada da rede até a saída.

Os parâmetros do modelo podem ser representados como matrizes da seguinte maneira:

$$\theta^{(1)} = \begin{bmatrix} \theta_{10} & \theta_{11} & \theta_{12} & \dots & \theta_{1n} \\ \theta_{20} & \theta_{21} & \theta_{22} & \dots & \theta_{2n} \\ \theta_{30} & \theta_{31} & \theta_{32} & \dots & \theta_{3n} \\ \dots & \dots & \dots & \dots & \dots \\ \theta_{n0} & \theta_{n1} & \theta_{n2} & \dots & \theta_{nn} \end{bmatrix} \quad \theta^{(2)} = [\theta_{10} \quad \theta_{11} \quad \theta_{12} \quad \dots \quad \theta_{1n}]$$

Na RNA apresentada na Figura 26 pode-se observar uma única camada escondida, mas podem-se projetar redes com várias camadas escondidas, bem como usando um número maior de unidades na camada escondida (comparado

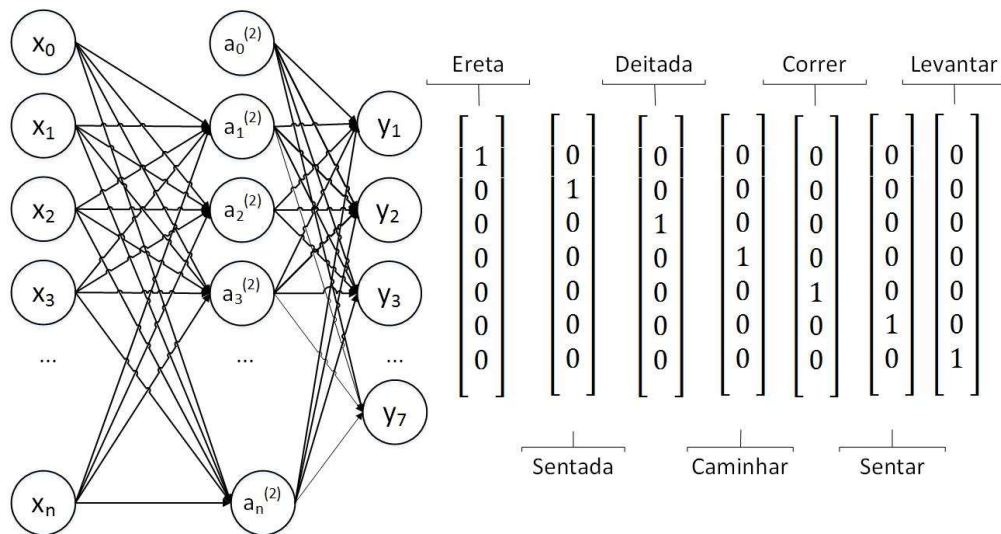
com o número de entradas) para melhorar o desempenho da rede. Entretanto há um aumento da complexidade computacional que motiva a busca de um equilíbrio entre estes parâmetros. Geralmente uma rede com uma camada escondida e com o mesmo número de unidades nas camadas 1 e 2 apresenta um bom desempenho.

A RNA projetada para o sistema SIRAH possui três camadas:

- A camada de entrada, onde são apresentados os atributos calculados em cada janela. O número de unidades na camada de entrada é igual ao número de atributos, sendo este um parâmetro que muda nos diferentes testes;
- A camada escondida, com um número de unidades igual ao número de unidades da camada de entrada;
- A camada de saída. Devido à necessidade de diferenciar entre mais de uma categoria (3 posturas e 4 atividades, somando 7 em total), a RNA do sistema SIRAH se enquadra em um problema de multiclassificação, como se observa na Figura 27. Neste caso o procedimento requer treinar o algoritmo para cada classe, o que implica construir sete hipóteses, uma para a classificação de cada postura e atividade.

Quando se estiver treinando uma classe, as outras se tornam em uma única classe, procedimento conhecido como “um contra todos”. Na Figura 27 é apresentado o valor do vetor de saída dependendo da postura ou atividade representada pelos dados de entrada.

Figura 27 - RNA do sistema SIRAH



Fonte: Elaboração da própria autora.

O treinamento da RNA consiste em aprender os parâmetros das camadas 1 e 2,  $\theta^{(1)}$  e  $\theta^{(2)}$ , que melhor se ajustem ao conjunto de treinamento, de tal maneira que o modelo construído pelo algoritmo seja muito parecido com a função real, para todos os exemplos de treinamento.

O conjunto de exemplos de treinamento está formado por pares de entradas-saída. As entradas são os atributos extraídos das janelas previamente normalizados, e a saída é a classe a que correspondem esses atributos e que representa a postura ou a atividade.

Na Tabela 2 apresenta-se um exemplo de treinamento para cada uma das posturas e atividades. A saída é codificada como se indica na Figura 27 e os exemplos pertencem ao conjunto de atributos do primeiro estudo de caso [média aritmética  $(\bar{x}, \bar{y}, \bar{z})$ , desvio padrão  $(s_x, s_y, s_z)$ , assimetria  $(S(x), S(y), S(z))$ , curtose  $(k(x), k(y), k(z))$  e excentricidade  $(\lambda_1, \lambda_2, \lambda_3)$ ]. Para treinar a RNA foi aplicado o algoritmo *Back Propagation*.

Tabela 2 - Exemplos de treinamento do primeiro estudo de caso.

Atributos															Saída
$\bar{x}$	$\bar{y}$	$\bar{z}$	$s_x$	$s_y$	$s_z$	$S(x)$	$S(x)$	$S(x)$	$k(x)$	$k(x)$	$k(x)$	$\lambda_1$	$\lambda_3$	$\lambda_3$	Y
-0,17	-0,56	-0,46	-0,77	-0,71	-1,03	-0,23	-0,00	0,02	0,21	0,43	-0,23	-0,61	-0,68	-0,56	1000000
1,11	-0,34	0,93	-0,77	-0,71	-1,10	0,08	-0,71	-1,13	-0,14	0,39	0,14	-0,61	-0,68	-0,56	0100000
-1,09	2,41	2,03	-0,77	-0,71	-1,10	-2,00	-0,472	-0,04	0,77	0,20	0,74	-0,61	-0,68	-0,56	0010000
-0,96	-0,61	-0,33	1,39	0,33	0,03	-0,98	-0,01	-0,64	-0,08	-0,32	-0,13	0,91	0,51	-0,18	0001000
1,28	-0,39	-0,59	1,50	2,38	1,42	-0,60	0,24	0,11	0,49	-0,39	-0,46	1,29	2,61	2,59	0000100
0,73	-0,11	-0,88	-0,34	-0,18	1,11	-0,04	-0,25	0,81	-1,49	-0,54	-0,34	-0,58	-0,41	-0,19	0000010
0,48	-0,20	-0,79	-0,47	-0,25	1,15	-1,21	0,27	0,66	2,14	-0,57	-0,40	-0,55	-0,31	-0,21	0000001

Fonte: Elaboração da própria autora.

O treinamento da rede é realizado aplicando *Back Propagation*, procedimento que calcula a diferença entre a saída atual e a saída desejada (valor real da função nos exemplos de treinamento) e modifica os pesos desde a saída até a entrada. Esta diferença é expressada mediante uma função de custo, que é minimizada aplicando um algoritmo de otimização.

Durante o treinamento, um exemplo é apresentado à RNA e com os pesos inicializados aleatoriamente, são calculadas as saídas de todas as unidades. A seguir, o valor do vetor de saída é comparado com o valor produzido pela rede. A diferença será o erro, que é retropropagado para modificar os pesos organizadamente, usando as derivadas parciais da função de custo, em relação aos mesmos parâmetros da rede  $\theta_{ji}^{(l)}$ . A modificação dos pesos é realizada iterativamente até chegar aos valores que minimizem a função de custo.

Após a segmentação das acelerações, têm-se 1.260 janelas, que correspondem a 1.260 exemplos disponíveis para as 3 posturas e as 4 atividades, 180 para cada uma. No treinamento foram usados 70% dos exemplos disponíveis, evitando que a rede se especialize nos dados, perdendo sua capacidade de generalizar. Os 30% restante foram usados para avaliação.

#### **4.5.8 Avaliação da RNA**

A precisão da rede foi medida usando os parâmetros do modelo final para calcular as saídas com os exemplos de avaliação, e calculando a porcentagem de vezes em que a classificação foi acertada.

O treinamento da RNA tem dois passos aleatórios: a seleção dos exemplos para o conjunto de treinamento e de avaliação, e a inicialização dos pesos. Com o objetivo de comparar os conjuntos de treinamento, com cada um, treinou-se a rede 20 vezes. A precisão foi calculada com a média dos resultados dos 20 treinamentos.

##### **4.5.8.1 Primeiro estudo de caso**

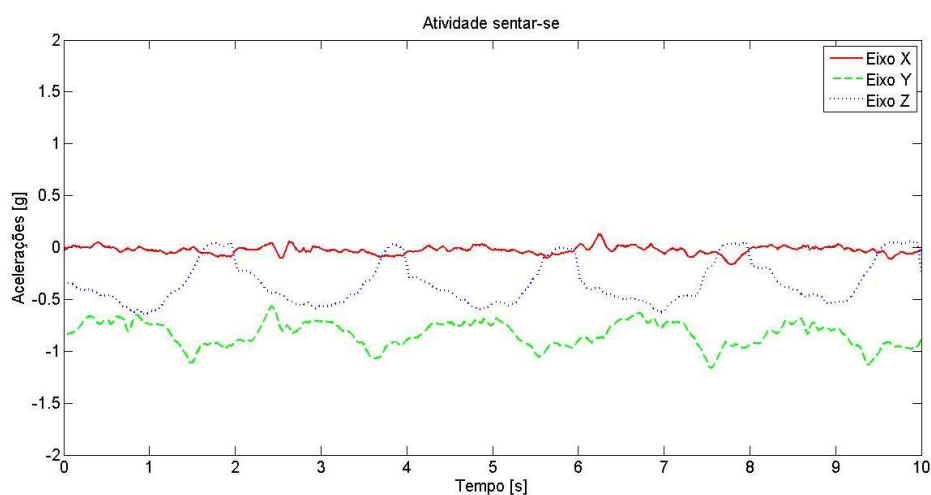
Neste estudo de caso, os atributos usados são: média aritmética, desvio padrão, assimetria, curtose e excentricidade para cada eixo, dando um total de 15 atributos, todos no domínio do tempo. Assim, a RNA projetada tem 15 unidades na camada de entrada, 15 na unidade escondida e 7 na camada de saída. Outras configurações com maior número de unidades na camada escondida foram testadas mas a precisão não melhorou. A precisão média alcançada pela RNA foi de 94,40%.

Os atributos deste primeiro estudo de caso foram tomados do trabalho de Baek *et al.* (2004), com o intuito de conferir resultados entres os dois sistemas por serem similares. No trabalho mencionado, os autores localizam um acelerômetro de dois eixos na cintura e classificam as posturas ereta, sentada deitada, caminhar, correr, subir e descer escadas com uma precisão geral de 97,5%.

A precisão média alcançada pelo sistema SIRAH neste estudo de caso é de 94,40%. Comparando os as duas precisões, mesmo tendo uma precisão menor, nota-se que o sistema SIRAH tem um desempenho adequado.

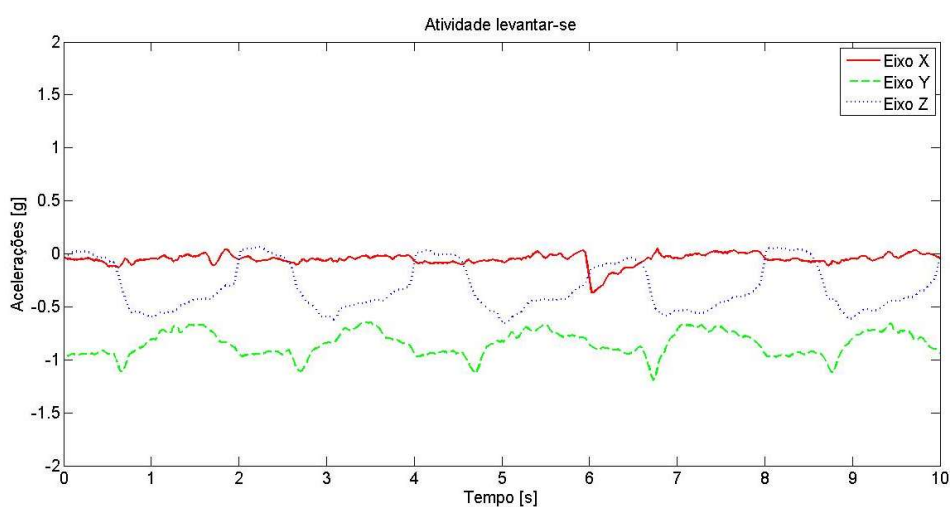
A diferença na precisão pode estar relacionada com o tipo de atividade classificada. Ao subir e descer escadas, os sinais de aceleração apresentam variações acentuadas que se refletem nos conjuntos de atributos, cujos valores podem mudar de maneira marcante e apresentam pouca sobreposição entre atividades. Por outro lado, nas atividades sentar-se e levantar-se o acelerômetro gera sinais que, ao ser separados e segmentados, ficam muito parecidos como se observa nas figuras 28 e 29.

Figura 28 - Atividade sentar-se



Fonte: Elaboração da própria autora.

Figura 29 - Atividade levantar-se



Fonte: Elaboração da própria autora.

#### **4.5.8.2 Segundo estudo de caso**

O segundo estudo de caso foi realizado com a intenção de verificar se ao aumentar e diversificar os atributos, a precisão na classificação da rede melhoraria. O conjunto de atributos usado neste caso, está formado pelos atributos do primeiro estudo de caso mais os encontrados no trabalho de da Silva e Galeazzo (2013), que incluem tanto atributos no domínio do tempo como da frequência. No trabalho indicado o acelerômetro foi localizado no punho para reconhecer as posturas ereta, sentada, deitada, caminhar, correr, subir e descer escadas e trabalhar no computador. Os atributos são: média aritmética, desvio padrão, variância, SMA, assimetria, curtose, correlação, excentricidade, variação, energia média, entropia espectral e magnitude máxima. Todos os atributos são extraídos para cada eixo, menos SMA, que consiste em um valor calculado com os três eixos, sendo que o conjunto total tem 34 elementos

A RNA projetada para este estudo de caso tem 34 unidades na camada de entrada e na camada intermediária e 7 unidades na camada de saída. Ao contrário do que se suponha inicialmente, o aumento do número de atributos e a inclusão de atributos no domínio da frequência, não melhorou significativamente a precisão do modelo. A rede classificou corretamente as atividades em 94.35% dos casos, valor muito próximo ao obtido no teste anterior. Assim, pode-se constatar que incluir mais atributos, nem sempre ajuda na melhora da classificação do modelo.

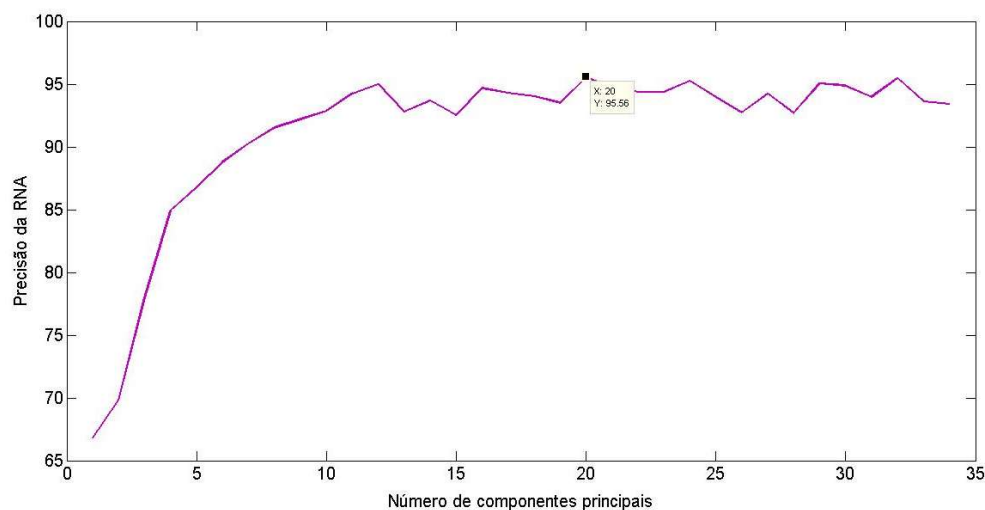
#### **4.5.8.3 Terceiro estudo de caso**

Como indicado na seção 0, a escolha automática de atributos foi implementada com base no algoritmo PCA, a partir do conjunto base do segundo estudo de caso com 34 elementos.

O PCA fornece os componentes principais, organizados decrescentemente, sendo que o tamanho inicial pode ser reduzido eliminando-se os componentes mais fracos. Decidiu-se testar o desempenho da rede treinada com um componente principal, depois com dois componentes principais, depois com 3, 4, 5, 6, até completar os 34.

Na medida que são acrescentados mais componentes principais, a precisão da rede melhora, até chegar num ponto em que se estabiliza como pode-se verificar na Figura 30.

Figura 30 - Precisão PCA



Fonte: Elaboração da própria autora.

O critério usado para selecionar o número de atributos, ou seja, o número de componentes principais, foi escolher aquele conjunto que apresentasse melhor desempenho que o conjunto do primeiro estudo de caso. Deste modo, o menor número de componentes principais, com o qual o conjunto obtido aplicando PCA supera o conjunto de primeiro estudo de caso é de 12, com uma precisão média de 94,98%.

Se for necessária uma precisão maior, por exemplo, superior a 95%, pode-se escolher uma maior quantidade de componentes principais. Com 20 componentes principais a precisão da RNA aumenta a 95,55% como se observa na Figura 30.

Em relação à precisão do modelo apresentado por da Silva e Galeazzo (2013), cujos atributos foram usados no segundo e terceiro estudo de caso, é impossível realizar uma comparação direta com o sistema SIRAH, pois os sistemas diferem em:

- A localização do sensor. Os autores do trabalho mencionado fixaram o acelerômetro no punho;
- As atividades a serem identificadas, indicadas no segundo estudo de caso.

Porém, nos dois trabalhos foram usados uma RNA como classificador e o método PCA para escolher atributos. A precisão deles é igual a 90,91% com 21 atributos. A precisão do sistema SIRAH é de 95,55% com 20 atributos, com o que se poderia entender que a cintura é uma melhor opção para localizar o sensor no reconhecimento de atividades globais, como já tem sido indicado na literatura relacionada (CORNACCHIA *et al.*, 2017).

Na Tabela 3 é apresentado um resumo dos resultados dos três testes onde se nota que os valores da precisão da RNA são muito próximos.

Tabela 3 - Precisão dos estudos de caso realizados

<b>Teste realizado</b>	<b>Precisão [%]</b>
<b>Primeiro estudo de caso</b>	94,40
<b>Segundo estudo de caso</b>	94,35
<b>Terceiro estudo de caso</b>	94,51

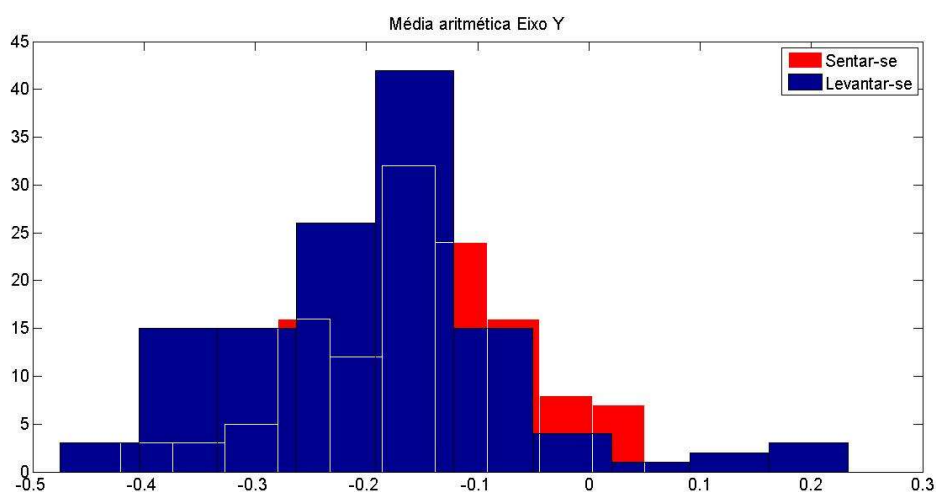
Fonte: Elaboração da própria autora.

Concluídos os estudos de caso e notando que aumentar e diversificar as entradas da RNA não teve um impacto significativo na precisão da RNA, avaliou-se o desempenho do modelo obtido no primeiro estudo de caso, para cada

postura e atividades independentemente. Este modelo classificou todas as posturas e as atividades caminhar e correr com uma precisão igual a 100%, mas este valor caiu para a atividade sentar-se em 88.8% e levantar-se 73,37%.

Realizando uma avaliação visual dos 15 atributos selecionados observa-se que estes apresentam sobreposição para as atividades sentar-se e levantar-se, pois os valores estão na mesma faixa. Este fato se observa na Figura 31, onde se ilustra a média aritmética do eixo Y para as duas atividades.

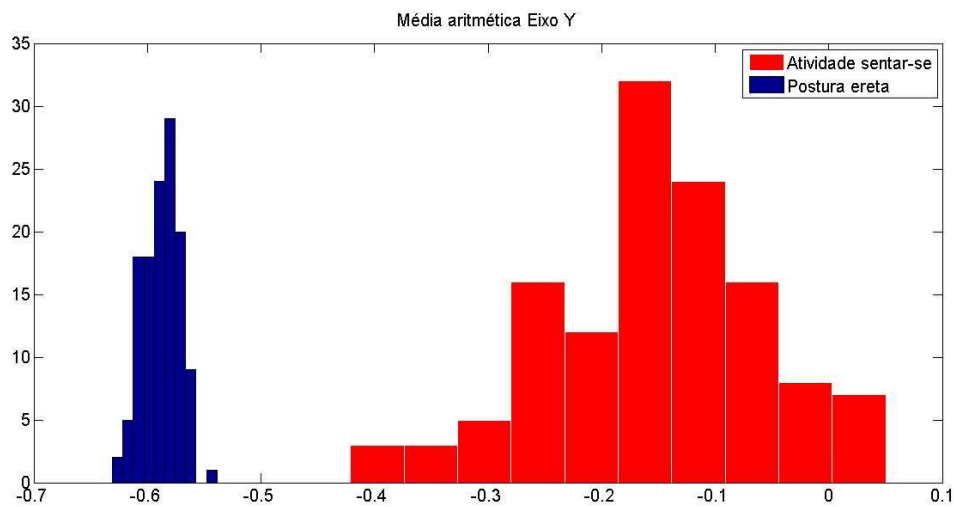
Figura 31 - Média eixo Y nas atividades sentar-se e levantar-se.



Fonte: Elaboração da própria autora.

Por outro lado, analisando o mesmo atributo para a postura ereta e a atividade sentar-se, este mostra variações consideráveis como se observa na Figura 32. A mesma situação foi observada com os outros atributos.

Figura 32 - Média eixo Y na atividade sentar-se e a postura ereta

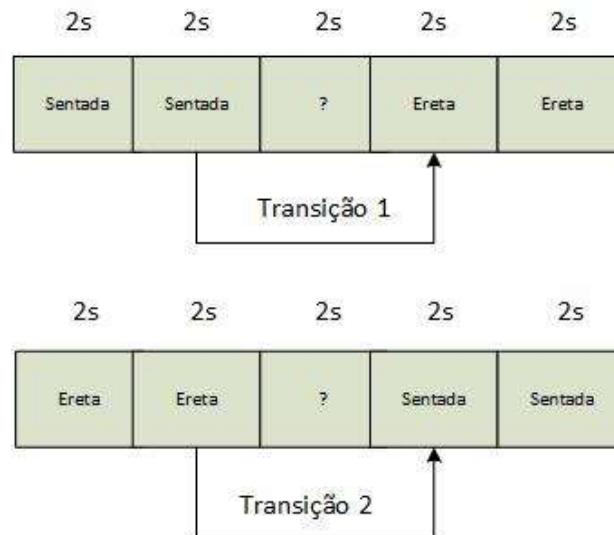


Fonte: Elaboração da própria autora.

Desta maneira, o erro do classificador é atribuído às atividades selecionadas, particularmente, às atividades sentar-se e levantar-se pois o acelerômetro gera sinais que ao ser segmentados ficam muito parecidos

Para melhorar a precisão do sistema SIRAH na classificação das atividades sentar-se e levantar-se, têm-se três possibilidades. A primeira consiste em implementar a sobreposição na segmentação, com o objetivo de analisar os sinais das acelerações de forma mais continua no tempo. Neste caso, cada janela teria, por exemplo, 50% da janela anterior, evitando perder características relevantes dos sinais localizados na união entre janelas. A segunda aborda uma análise dos sinais para procurar atributos heurísticos, relacionados com os movimentos e posturas específicas das duas atividades que permitam diferenciá-las. A terceira possibilidade consiste em analisar as posturas e atividades já classificadas com algum dos três modelos obtido depois do treinamento e detectar transições entre as posturas sentada e ereta, como é mostrado na Figura 33.

Figura 33 – Transições entre as posturas sentada e ereta



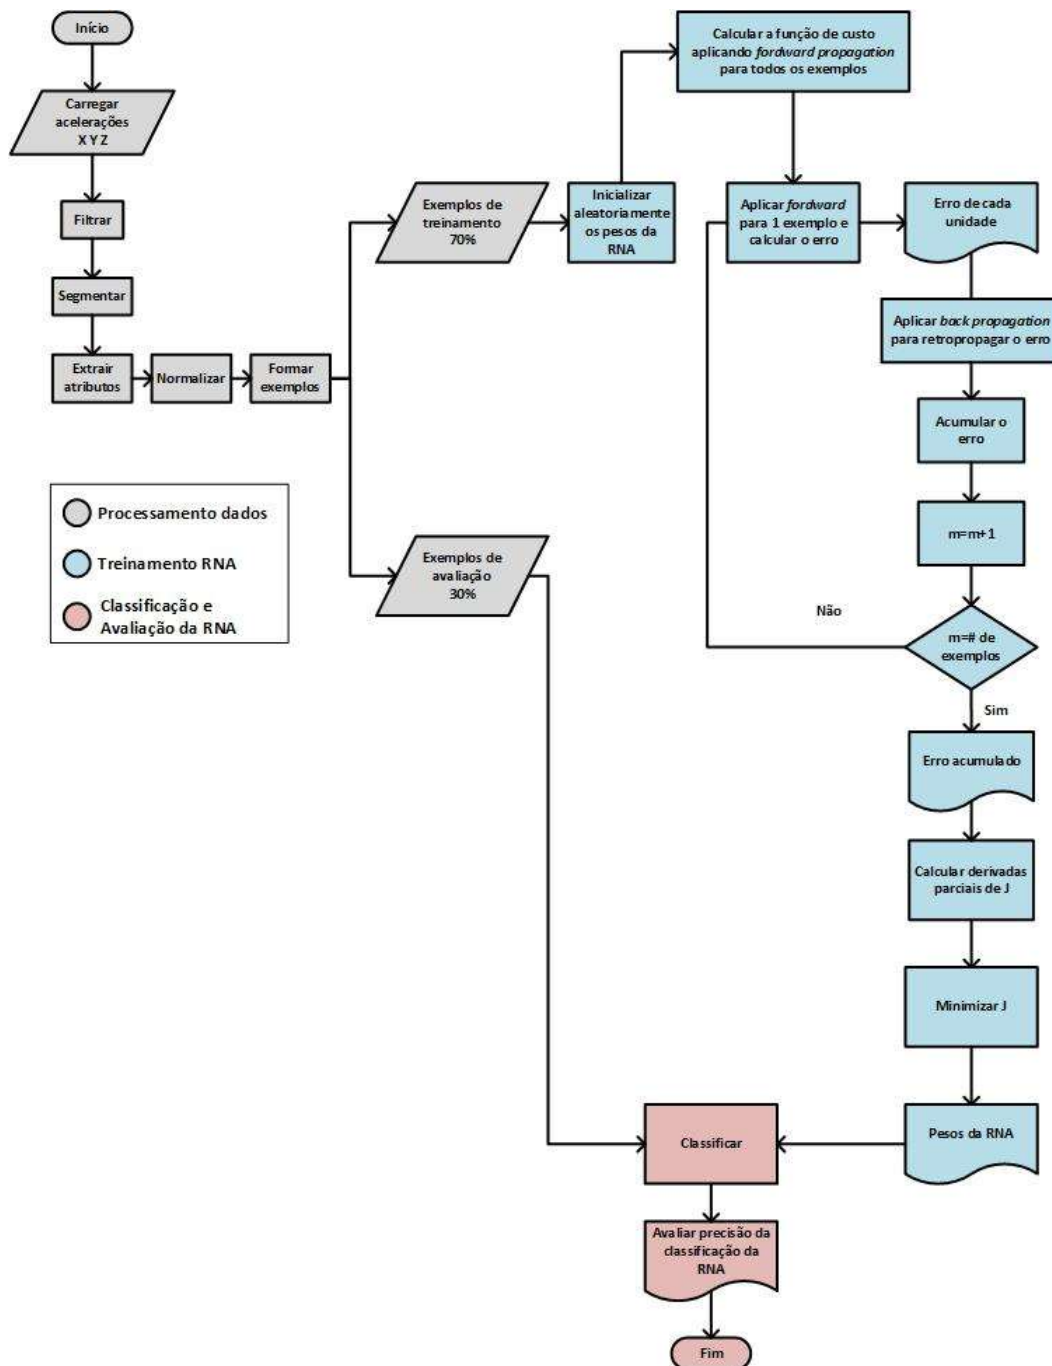
Fonte: Elaboração da própria autora.

Desta forma, a transição 1 representa a atividade levantar-se e a transição 2 representa a atividade sentar-se. Cabe salientar que esta última opção poderia ser implementada somente na classificação *Online*, que será explicada na seguinte seção 0.

#### 4.5.9 Implementação em Matlab da fase *Offline*

O algoritmo descrito com a linguagem própria do Matlab, para implementar a fase *Offline* do reconhecimento *Offline* do SIRAH, está representado na Figura 34. Os passos envolvidos no processamento dos dados estão representados com os blocos na cor cinza da Figura 34. O algoritmo inicia carregando as acelerações das 3 posturas e 4 atividades, transferidas desde a memória SD ao computador, e armazenadas em arquivos com extensão “.m.” O primeiro processo aplicado é a filtragem, utilizando a função própria de Matlab ‘*smooth*’ com um número de coeficientes igual a três.

Figura 34 – Fluxograma do algoritmo implementado em Matlab



Fonte: Elaboração da própria autora.

Em seguida, o algoritmo segmenta os sinais, processo que consiste em tomar o número de amostras do sinal para formar uma janela. Como o período de amostragem é igual a 25ms  $\left(T_s = \frac{1}{40 \text{ Hz}}\right)$ , uma janela de 2s contém 80 amostras. Para cada postura e atividade têm-se 180 janelas, sendo um total de 1260 janelas.

Em cada janela são extraídos os diferentes atributos; neste processo foram usadas as funções próprias do Matlab quando possível (por exemplo, média '*mean*', desvio padrão '*std*', entre outras). Para os atributos que não possuem função de Matlab, foram implementadas as equações indicadas no Quadros 5 e 6. No caso dos atributos no domínio da frequência, primeiro aplicou-se a Transformada Discreta de Fourier, com a função '*fft*' e depois calculou-se o respectivo atributo. Deste modo, o algoritmo computa os 34 atributos e forma uma matriz de 1260 linhas e 34 colunas.

A normalização dos atributos é realizada por colunas, ou seja, por atributos. Após a normalização, são formadas as matrizes dos conjuntos de treinamento nos que mudam os atributos incluídos:

- O conjunto para o Primeiro estudo de caso é uma matriz de 1260×15, sendo 1260 os exemplos de treinamento e 15 os atributos indicados em 0;
- O conjunto para o Segundo estudo de caso é uma matriz de 1260×34, sendo 1260 os exemplos de treinamento e 34 os atributos indicados em 0;
- O conjunto base para o Terceiro estudo de caso é o mesmo que o anterior.

No conjunto de cada caso, são escolhidos de forma aleatória 70% para o treinamento e 30% para a avaliação, mantendo a mesma quantidade de exemplos para cada postura e atividade.

A seguir, começa o treinamento da RNA, representado na Figura 34 com os blocos de cor azul. Primeiro são inicializados os pesos aleatoriamente; imediatamente se define a função de custo e suas derivadas parciais em relação aos pesos. Esta informação será usada pela função de otimização '*fminunc*' do Matlab, que tem como entrada os pesos inicializados aleatoriamente e os

exemplos de treinamento; a saída da função de otimização está formada pelos pesos que minimizam a função de custo.

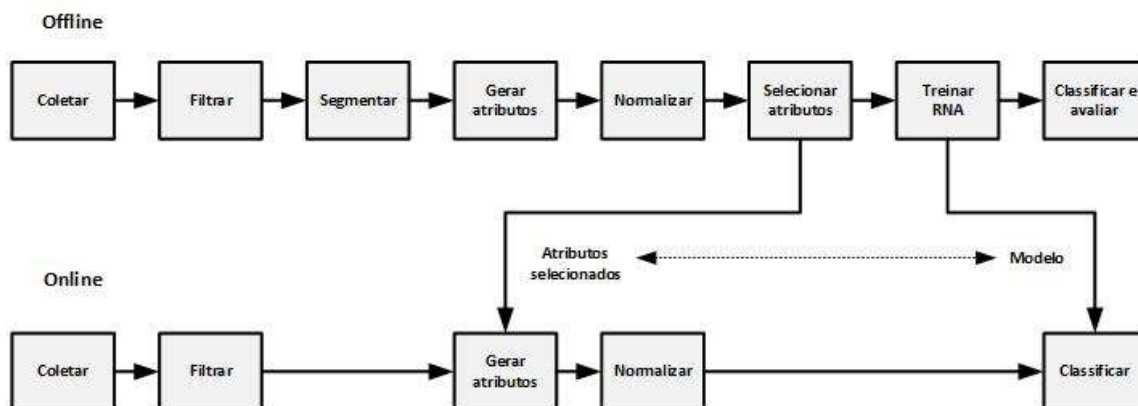
Finalmente, com os pesos da RNA, são classificados os exemplos de avaliação, e comparando estes resultados com a saída real, pode ser ver quantas vezes classificou-se corretamente as posturas e as atividades, e desta forma conhecer a precisão do modelo. Este último processo é representado na Figura 34 com os blocos na rosa.

#### 4.6 FASE ONLINE

A classificação das posturas e das atividades, apresentada na seção 0, corresponde à fase *Offline* realizada em um computador. Entretanto o sistema SIRAH possibilita a monitorização de pessoas, com a classificação de posturas e atividades realizada *Online*. Por classificação *Online* entende-se que os processos de filtragem, geração e normalização de atributos e finalmente, a classificação com um modelo previamente treinado, são realizados no protótipo no momento da ocorrência, e não no computador, como se observa na Figura 35.

Nesta ordem de ideias, a abordagem *Online* adotada foi a implementação em um microcontrolador, dos processos indicados na Figura 35 junto com um dos modelos de classificação obtidos no treinamento *Offline*. Deve-se destacar que os atributos a gerar correspondem com o modelo selecionado, como se observa na Figura 35.

Inicialmente, a coleta de dados do acelerômetro foi realizada com o microcontrolador ATmega328; porém, devido as limitações de memória do dispositivo, escolheu-se trabalhar com o ATmega2560, da placa Aduino Mega, que cumpre com os requisitos necessários para a implementação *Online* do SIRAH.

Figura 35 – Fase *Offline* versus Fase *Online*.

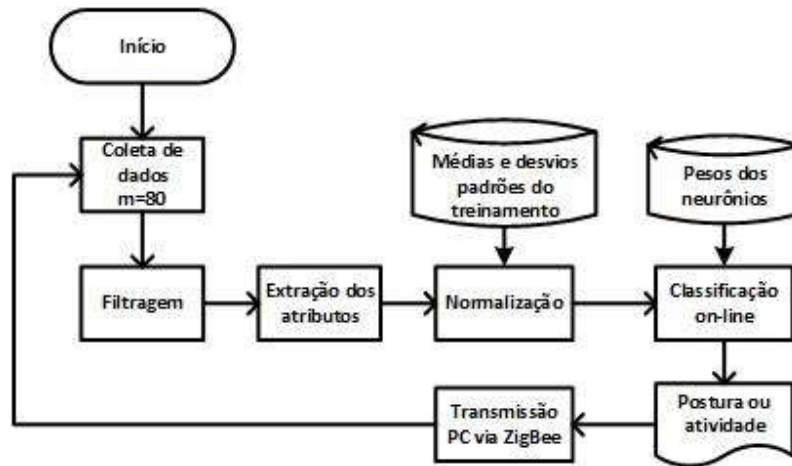
Fonte: Elaboração da própria autora.

#### 4.7 DESENVOLVIMENTO DO SISTEMA EM UM MICROCONTROLADOR ATMEGA2560

Como foi descrito na seção 0, o algoritmo do sistema SIRAH foi desenvolvido na linguagem própria do Matlab. Para o reconhecimento *Online*, optou-se por codificar esse algoritmo na linguagem C, pois várias plataformas a suportam, possibilitando a comparação e análise dos resultados gerados por diferentes dispositivos.

A codificação em C foi desenvolvida no compilador GCC e consiste na implementação dos processos contidos na Figura 35, indicados para a classificação *Online*. Esse procedimento está representado no fluxograma da Figura 36, que se estende desde a coleta dos dados do acelerômetro, até o envio da postura ou atividade classificada ao computador. A programação do ATmega2560 foi desenvolvida usando o software livre para Arduino.

Figura 36 - Fluxograma da classificação *Online*.



Fonte: Elaboração da própria autora.

Os dados do acelerômetro são coletados com as mesmas características de funcionamento indicadas na seção 0: sensibilidade de  $\pm 8g$ , com 10 bits de resolução e uma taxa de amostragem de 40 Hz. Visto que o treinamento foi realizado segmentando os sinais com janelas de 2s sem sobreposição, são armazenadas 80 amostras dos três eixos, formando assim uma janela que pode ser classificada.

Quando as 80 amostras dos três eixos estão prontas, estes sinais são filtrados com o filtro de média móvel, implementado em C conforme a Equação 9:

$$xf_{[i]} = \frac{1}{C} \sum_{-(C-1)/2}^{(C-1)/2} x_{[i+j]}, 1 < i < m \quad (9)$$

Nesta Equação 9,  $C$  é o número de coeficientes para calcular a média,  $xf$  e  $x$  são os sinais de saída e entrada do eixo X, respectivamente, e  $m$  é a quantidade de amostras pertencentes a  $x$ . A mesma equação é aplicada nos eixos Y e Z.

No sistema SIRAH utilizou-se um filtro de 3 coeficientes, e como o intervalo do cálculo das médias é simétrico, o filtro é aplicado da segunda amostra até a penúltima.

O conjunto de atributos escolhido nesta abordagem foi o mesmo utilizado no primeiro estudo de caso, que inclui: média aritmética, desvio padrão, assimetria, curtose e excentricidade. Esta escolha esteve baseada em três fatores:

- O bom desempenho apresentado pelo modelo construído com base neste conjunto;
- A pouca melhora observada ao incluir uma maior quantidade de atributos;
- O conjunto não contém atributos no domínio da frequência, não necessitando implementar a Transformada de Fourier. Isto aumentaria a complexidade computacional e o tempo de execução do algoritmo.

Para a normalização dos atributos, são necessárias as médias aritméticas  $\bar{A}$  e desvios padrões  $s_A$  de cada um, como indicado na seção 0 (Geração de atributos). Estes valores foram obtidos na fase *Offline* e incorporados ao algoritmo em C para o microcontrolador. Uma vez gerados os atributos em cada janela, estes são normalizados executando uma função que implementa a Equação 10:

$$A_j = \frac{A_j - \bar{A}}{s_A} \quad (10)$$

Sendo  $A_j$  o atributo sem normalizar e  $A_j$  o atributo normalizado. Com os atributos normalizados, cada janela é classificada através do modelo obtido no treinamento *Offline*. O modelo é formado por duas matrizes contendo os pesos dos neurônios, que também foram incorporados ao código em C, e têm a seguinte forma:

$$\Theta^{(1)} = \begin{bmatrix} \theta_{1,0} & \theta_{1,1} & \theta_{1,2} & \dots & \theta_{1,15} \\ \theta_{2,0} & \theta_{2,1} & \theta_{2,2} & \dots & \theta_{2,15} \\ \theta_{3,0} & \theta_{3,1} & \theta_{3,2} & \dots & \theta_{3,15} \\ \dots & \dots & \dots & \dots & \dots \\ \theta_{15,0} & \theta_{15,1} & \theta_{15,2} & \dots & \theta_{15,15} \end{bmatrix}_{15 \times 16}$$

$$\Theta^{(2)} = \begin{bmatrix} \theta_{1,0} & \theta_{1,1} & \theta_{1,2} & \dots & \theta_{1,15} \\ \theta_{2,0} & \theta_{2,1} & \theta_{2,2} & \dots & \theta_{2,15} \\ \theta_{3,0} & \theta_{3,1} & \theta_{3,2} & \dots & \theta_{3,15} \\ \dots & \dots & \dots & \dots & \dots \\ \theta_{7,0} & \theta_{7,1} & \theta_{7,2} & \dots & \theta_{7,15} \end{bmatrix}_{7 \times 16}$$

A classificação da atividade é obtida aplicando o processo *feed forward*, previamente explicado:

1. Forma-se a matriz dos 15 atributos normalizados mais o bias:

$$X = [x_0 \quad x_1 \quad x_2 \quad x_3 \quad \dots \quad x_{15}]_{1 \times 16}$$

2. O mapeamento dos atributos da camada de entrada até a segunda é realizado multiplicando  $X$  pela matriz dos neurônios  $\Theta^{(1)}$ :

$$X\Theta^{(1)T} = [a_1 \quad \dots \quad a_{15}]_{1 \times 15}$$

3. O mapeamento da segunda camada até a camada de saída, que entrega a classificação da atividade, é realizado multiplicando o resultado anterior (adicionando o bias  $a_0$ ) pela matriz dos neurônios  $\Theta^{(2)}$ :

$$[a_0 \quad \dots \quad a_{15}]_{1 \times 16} \Theta^{(2)T} = [y_1 \quad y_2 \quad y_3 \quad y_4 \quad y_5 \quad y_6 \quad y_7]$$

Após a classificação de uma janela, o processo é repetido quantas vezes seja necessário. Nesta abordagem, enquanto o microcontrolador executa os processos de filtragem, geração e normalização de atributos, e classificação da janela, os dados do acelerômetro não são coletados, devido à natureza sequencial do microcontrolador. No ATmega2560, a execução destes processos mais a transmissão da atividade classificada tem duração de 250 ms, que representa aproximadamente 12% de uma janela. Este lapso é aceitável no monitoramento de pessoas. Porém, procurando ter uma classificação mais rápida, um trabalho

futuro para pesquisa será a implementação dos processos explicados nesta seção em um FPGA, (*Field Programmable Gate Array*, em português Arranjo de Portas Programável em Campo). Por suas características, este dispositivo permite execução em paralelo, o que será aproveitado para aumentar a velocidade de processamento das acelerações dos três eixos do sensor.

Com a implementação da classificação *Online*, é possível utilizar o sistema SIRAH para monitorar as atividades diárias realizadas por uma pessoa em seu lar, o que abre uma série de possibilidades, entre as que se podem mencionar:

- Conhecer a quantidade de atividade que realiza uma pessoa em seu cotidiano e, desta forma, identificar hábitos e rotinas. Esta informação é fundamental no tratamento de pessoas com sobrepeso ou diabetes, que precisam ter uma quantidade mínima de atividade física diária;
- Identificar tempos longos de inatividade, por exemplo, de idosos que morem sozinhos e, desta forma, ativar os alarmes respectivos, seja para avisar a seus cuidadores, familiares ou aos serviços de emergência.

Além do monitoramento, o sistema SIRAH pode ser usado para monitorar parâmetros relacionados com cada postura e atividade, como por exemplo, taxa de passos ao caminhar, tempo de subida ao levantar-se e oscilação corporal na postura ereta semi-estática.

A capacidade de manter o equilíbrio postural frequentemente diminui com o processo de envelhecimento e algumas doenças, deixando a pessoa com maior risco de sofrer quedas, o torna interessante contar com ferramentas de análise e quantificação do equilíbrio. Por isto, decidiu-se pesquisar a capacidade do sistema SIRAH na avaliação da oscilação corporal. Este tópico é abordado no Capítulo 5.

## 5 SIRAH: AVALIAÇÃO DO EQUILÍBRIO POSTURAL

O equilíbrio postural se refere à habilidade de manter a posição do corpo (centro de massa, CM) dentro dos limites de estabilidade, através da inter-relação das forças que atuam sobre o corpo, incluindo a força da gravidade, dos músculos e a inércia (TEIXEIRA, 2013).

A manutenção do equilíbrio do corpo é atribuída ao sistema de controle postural, um conceito usado para se referir às funções dos sistemas sensorial, motor e nervoso que desempenham esse papel (DUARTE; FREITAS, 2010). No sistema sensorial estão incluídos:

- O sistema vestibular, que está composto por um grupo de órgãos localizados no ouvido interno dos vertebrados. Provê informações relativas à posição da cabeça em relação à gravidade e aos movimentos lineares e rotatórios da cabeça;
- O sistema somatossensorial, que permite experimentar sensações da posição e movimentos das partes do corpo;
- O sistema visual que provê informação global do corpo, suas partes e o meio no qual se encontra (SOARES, 2010).


O sistema motor é responsável pela ativação correta e adequada de músculos para a realização dos movimentos e o sistema nervoso central integra informações provenientes do sistema sensorial para enviar impulsos aos músculos que geram respostas neuromusculares (DUARTE; FREITAS, 2010).

A maneira mais comum de avaliar o equilíbrio corporal é medindo a oscilação corporal na postura ereta semi-estática. Esta oscilação provoca um deslocamento do CM nos eixos ântero-posterior (AP), e médio-lateral (ML), apresentados na Figura 37. Formalmente, o CM se define como a média ponderada do CM de cada segmento do corpo no espaço tridimensional (SAUNDERS, 2013); o centro de gravidade (CG), representa a projeção vertical do

CM no solo. A medição do centro de pressão (CP) é mais acessível que a do CM, pelo que a maioria das pesquisas na área estão baseadas no deslocamento do CP, utilizando uma plataforma de força, como se observa na Figura 37.

Como a posição vertical do CM não varia muito na postura ereta semi-estática, apresentam interesse somente os eixos horizontais.

Figura 37- Representação dos eixos ântero-posterior e médiolateral no corpo humano, plataforma de força e a trajetória do CP.



Fonte: Adaptada de Duarte e Freitas (2010).

O CP é a média ponderada das pressões em contato com o solo ou na plataforma de força. O CP apresenta padrões de movimento similares aos do CM, sempre que o corpo se movimenta como um pêndulo invertido com o pivô localizado no tornozelo, o qual é assumido na postura ereta semi-estática. Desta forma, o estudo do CP permite obter medições objetivas do equilíbrio postural (SAUNDERS, 2013).

A maioria dos sistemas fisiológicos declinam com a idade. Além disso, existem condições patológicas que podem diminuir ou remover um sistema sensorial como por exemplo, neuropatia periférica, degeneração muscular, perda

vestibular, entre outras, causando distúrbios do equilíbrio postural (SAUNDERS, 2013).

Na disfunção do equilíbrio postural, a amplitude da oscilação corporal pode exceder os limites de estabilidade e contribuir em uma queda. As quedas podem ser o resultado de fatores extrínsecos e intrínsecos. A contribuição de cada um muda com a idade. No envelhecimento existe um decremento nas causas externas devido a que a participação em atividades arriscadas diminui. Simultaneamente existe um aumento das causas intrínsecas devido ao declínio funcional normal relacionado com a idade, pois parte do processo de envelhecimento normal, envolve decrementos nos receptores periférico, na função nervosa, cognição, atenção e na força muscular, altamente envolvidos na regulação de postura ereta. Assim, a disfunção do equilíbrio postural tem sido identificada como um fator de risco importante para futuras quedas, pelo que resulta interessante contar com uma ferramenta para seu análise e quantificação (SAUNDERS, 2013).

Quando os pesquisadores têm interesse na identificação de problemas no equilíbrio postural aplicam testes que alteram um ou dois componentes do sistema sensorial, para avaliar a habilidade do indivíduo no uso dos outros componentes (SAUNDERS, 2013). Estes testes, como o de Romberg, ou a análise baseada na plataforma de força, requerem a presença de profissionais e o uso de equipamentos complexos, o que elimina a possibilidade de avaliar o equilíbrio postural continuamente, em ambientes externos a clínicas e laboratórios especializados.

O elemento central do sistema SIRAH é o acelerômetro. Este dispositivo tem sido usado em diversos trabalhos focados na avaliação da oscilação corporal tanto na postura ereta semi-estática quanto em atividades dinâmicas, como caminhar. Geralmente, os pesquisadores fixam o acelerômetro no sacro, perto do local do CM do corpo para medir diretamente as acelerações experimentadas pelo usuário, sobe diferentes condições que alteram um ou vários sistemas sensoriais.

Na pesquisa foram implementados dois métodos, que requerem o uso do acelerômetro nas costas: o primeiro calcula as acelerações do CM e o segundo calcula o deslocamento do CM. Estes dois métodos são descritos a seguir.

### 5.1 ANÁLISE DAS ACELERAÇÕES DO CENTRO DE MASSA

No trabalho apresentado por Moe-Nilssen e Helbostad (2002), os autores descrevem uma metodologia para diferenciar grupos e condições que aumentam progressivamente o desafio ao sistema de controle, com base nas acelerações geradas por um sensor localizado na região L3 (vertebra). Os grupos de indivíduos são idosos e jovens, e as condições avaliadas são resumidas na Tabela 4.

Tabela 4- Condições avaliadas com as acelerações horizontais.

<b>Visão</b>		<b>Posição dos pés</b>		<b>Superfície de suporte</b>	
Olhos abertos	Olhos fechados	Separados	Juntos	Firme	Instável

Fonte: Adaptada de Moe-Nilssen e Helbostad (2002).

Os autores Moe-Nilssen e Helbostad apontaram a existência de várias fontes de erro na medição das acelerações horizontais do CM. Contudo, apenas eliminando a inclinação do acelerômetro devido à curvatura das costas e possíveis erros na sua colocação, melhorou radicalmente a sensibilidade da medição. As outras fontes de erro analisadas não tiveram efeito nenhum na sensibilidade da medição, sendo que neste trabalho somente foi considerada a correção da inclinação.

Quando um eixo do acelerômetro não está na posição horizontal, registra-se a gravidade como um componente adicional a aceleração dinâmica causada pelo corpo. Desta forma, a inclinação será uma fonte de variabilidade nas

medições. Assume-se que a melhor estimativa da média aritmética da aceleração, enquanto está na postura ereta semi-estática é zero em qualquer dos eixos horizontais.

Definem-se três valores, todos mensurados em unidades de g:

- Aceleração medida,  $x$ . São os valores gerados pelo acelerômetro;
- Média aritmética da aceleração medida,  $\bar{x}$ ;
- Aceleração real  $x_R$ : São os valores da aceleração corrigida, uma vez eliminada a inclinação.

Uma média aritmética  $\bar{x} \neq 0g$ , é causada pela força de gravidade devido à inclinação constante do eixo medido. O ângulo de inclinação é indicado como  $\alpha$ ; o fator da gravidade será igual a  $g * \text{sen}(\alpha)$ , sendo  $g = 1$ . Portanto, se a aceleração média no eixo X é calculada, o ângulo de inclinação pode ser computado segundo a Equação 11:

$$\bar{x} = \text{sen}(\alpha) \quad (11)$$

A relação entre a aceleração medida e real, apresentada na Figura 38, está definida pela Equação 12:

$$x = x_R \cos(\alpha) + \text{sen}(\alpha) \quad (12)$$


Isolando  $x_R$  da Equação 12, tem-se a Equação 13:

$$x_R = \frac{x - \text{sen}(\alpha)}{\cos(\alpha)} \quad (13)$$

Substituindo a Equação 11 na 13, tem-se a Equação 14:

$$x_R = \frac{x - \bar{x}}{\cos(\arcsen(\bar{x}))} \quad (14)$$

Figura 38-Relação entre a aceleração medida em um eixo inclinado com um ângulo  $\alpha$  e a aceleração horizontal real.



Fonte: Adaptada de Moe-Nilssen e Helbostad (2002)


Desta forma, com base na aceleração medida, é possível calcular a aceleração real se a inclinação do acelerômetro permanecer constante durante todo o tempo de coleta de dados.

Aplicando este método podem-se calcular as acelerações reais nos eixos AP e ML. Como as acelerações são positivas e negativas, geralmente, utiliza-se o valor RMS como medida estatística de magnitude, para analisar diferentes condições que alteram o sistema de controle postural.

Neste trabalho o primeiro experimento aplicando este método foi realizado utilizando o acelerômetro MMA7455L. Na postura ereta semi-estática a oscilação é pequena, selecionou-se o intervalo de aceleração  $\pm 2g$ . Para este intervalo a resolução do dispositivo é de 8 bits e a sensibilidade é de 64 LSB/g, como indicado na folha de dados do sensor (FREESCALE, 2007).

Na Figura 39, é apresentada a aceleração medida no eixo ântero-posterior ( $AP$ ) na cor azul, e a aceleração real ( $AP_R$ ) obtida, na cor preta, uma vez aplicado o método de correção de inclinação. Como se observa na Figura 39 a  $AP_R$  tem uma média aritmética igual a  $0g$ .

Figura 39- Acelerações medida e real no eixo ântero-posterior AP, obtidas com o MMA7455L.



Fonte: Elaboração da própria autora.

No intervalo selecionado ( $\pm 2g$ ,  $4g$  em total), o valor do bit menos significativo, (*Least Significant Bit*, LSB) será igual a:

$$1LSB = \frac{4g}{2^8 \text{ counts}} = \frac{4g}{256 \text{ counts}} = 0,015625 \text{ g}$$


Este valor representa a menor quantidade que pode ser convertida dentro da faixa dinâmica do sinal de entrada, e como pode-se ver na Figura 39, o acelerômetro não consegue identificar mudanças na aceleração horizontal.

Por esta razão, utilizou-se o sensor MPU-6050 fabricado pela da InveSense (INVESENSE, 2013), que contém um acelerômetro de três eixos, com faixas de aceleração  $\pm 2g$ ,  $\pm 4g$ ,  $\pm 8g$ , e  $\pm 16g$  e 16 bits de resolução. Novamente, o intervalo de aceleração selecionado é  $\pm 2g$ , no qual o dispositivo tem uma sensibilidade igual a 16384 LSB/g. Desta maneira, o valor de um LSB será igual a:

$$1LSB = \frac{4g}{2^{16} \text{ counts}} = \frac{4g}{65536 \text{ counts}} = 6,10352 \text{ E} - 5 \text{ g}$$

Com esta resolução a sensibilidade na medição melhora consideravelmente. Na Figura 40 são apresentadas a aceleração medida e real no eixo AP obtida com o novo sensor, fixado com fita na região L3, e em detalhe, a aceleração AP corrigida, que exibe variações apreciáveis devido à oscilação do corpo.

Figura 40- Acelerações medida e real no eixo ântero-posterior AP, obtidas com o MPU-6050.



Fonte: Elaboração da própria autora.

## 5.2 ANÁLISE DO DESLOCAMENTO DO CENTRO DE MASSA

No trabalho de Mayagoitia *et al.* (2002) é apresentado um método para obter 5 parâmetros do CM:

- Velocidade média,  $V_m$ ;
- Raio médio,  $R_m$ ;
- Frequência média,  $F_m$ ;
- Deslocamento no eixo médio-lateral,  $d_{ML}$ ;
- Deslocamento no eixo ântero-posterior,  $d_{AP}$ .

Os cálculos são realizados com base nas acelerações dos três eixos X, Y e Z, geradas pelo sensor localizado na região da vertebra S2. Usando estes dados, calcula-se a magnitude do vetor da aceleração resultante:

$$A = \sqrt{x^2 + y^2 + z^2} \quad (15)$$


Com base na Figura 41, obtém-se um traçado do percurso do final deste vetor a partir dos ângulos diretores de A, expressados nas Equações 16, 17 e 18 :

$$\alpha = \arccos \frac{x}{A} \quad (16)$$

$$\beta = \arccos \frac{y}{A} \quad (17)$$

$$\gamma = \arccos \frac{z}{A} \quad (18)$$

Figura 41- Coordenadas da trajetória da projeção do vetor de aceleração no solo



Fonte: Adaptada de Mayagoitia *et al.* (2002).

Como o sistema espacial é o mesmo para D (vetor colinear do vetor de A) a magnitude de D pode ser calculada a partir da altura desde o chão até o acelerômetro,  $d_z$ , indicada na Equação 19:

$$D = -\frac{d_z}{\cos(\gamma)} \quad (19)$$

As coordenadas nos eixos ântero-posterior e médio-lateral podem ser obtidas pelas Equações 20 e 21:

$$d_y = D \cos(\beta) \quad (20)$$

$$d_x = D \cos(\alpha) \quad (21)$$

Este algoritmo é independente da inclinação do acelerômetro, pois as acelerações dos três eixos são combinadas para obter o resultado final. Porém, o método é válido se a distância entre o acelerômetro e o solo não muda, o que acontece na postura ereta semi-estática.

Os parâmetros, mostrados na Figura 42 são calculados aplicando as Equações 22, 23, 24, 25 e 26:

$$V_m = \frac{\sum \sqrt{((d_x - d_{x-1})^2 + (d_y - d_{y-1})^2)}}{T} \quad (22)$$

$$R_m = \frac{\sum \sqrt{((d_x - d_{xm})^2 + (d_y - d_{ym})^2)}}{n} \quad (23)$$

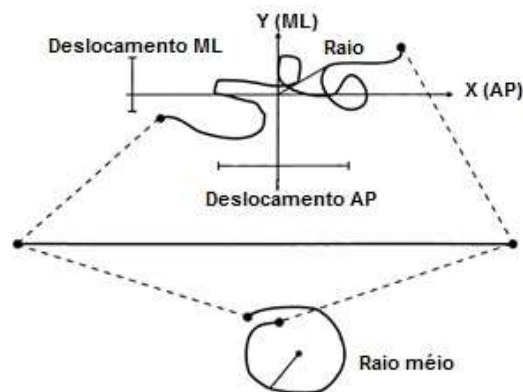
Sendo  $T$  o tempo total da medição,  $n$  o número de amostras e  $d_{xm}$  e  $d_{ym}$  as médias de todas as coordenadas X e Y.

$$F_m = \frac{V_m}{2\pi R_m} \quad (24)$$

$$d_{AP} = \max(d_x) - \min(d_x) \quad (25)$$

$$d_{ML} = \max(d_y) - \min(d_y) \quad (26)$$

Figura 42- Trajetória da oscilação corporal e cálculo dos parâmetros




Fonte: Adaptada de Mayagoitia *et al.* (2002).

O raio médio é interpretado como inversamente proporcional à estabilidade. Uma velocidade de oscilação baixa associa-se com uma maior estabilidade, pois indica que se realizam movimentos de ajuste bem controlados (MAYAGOITIA *et al.*, 2002).

Para testar este método, o acelerômetro foi colocado em um pêndulo e o ângulo foi variado manualmente entre 0-4° aproximadamente. O sistema do pêndulo pode ser descrito pela esquemática apresentada na Figura 43.

Figura 43- Pêndulo simples



Fonte: Elaboração da própria autora.

$L=180\text{mm}$ : comprimento do pêndulo.

$$\theta \cong 4$$


Como o ângulo de oscilação é pequeno, o deslocamento pode ser considerado a distância  $d_x$  ao invés do arco de circunferência.

$$x = L * \sin \theta$$

$$x \cong 12,5\text{mm}$$

Com este método os ângulos sempre são calculados em relação ao vetor resultante da combinação das três acelerações X, Y e Z. Na posição inicial, com o acelerômetro totalmente horizontal, os ângulos  $\alpha$ ,  $\beta$  e  $\gamma$  são apresentados conforme na Figura 44.


Figura 44 - Ângulos do método



Fonte: Elaboração da própria autora.

Os ângulos calculados com o acelerômetro nesta posição são apresentados na Figura 45. Como pode-se observar, os ângulos  $\alpha$  e  $\beta$  são iguais a  $90^\circ$  e o ângulo  $\gamma = 0^\circ$  em relação ao vetor resultante da combinação das três acelerações X, Y e Z.

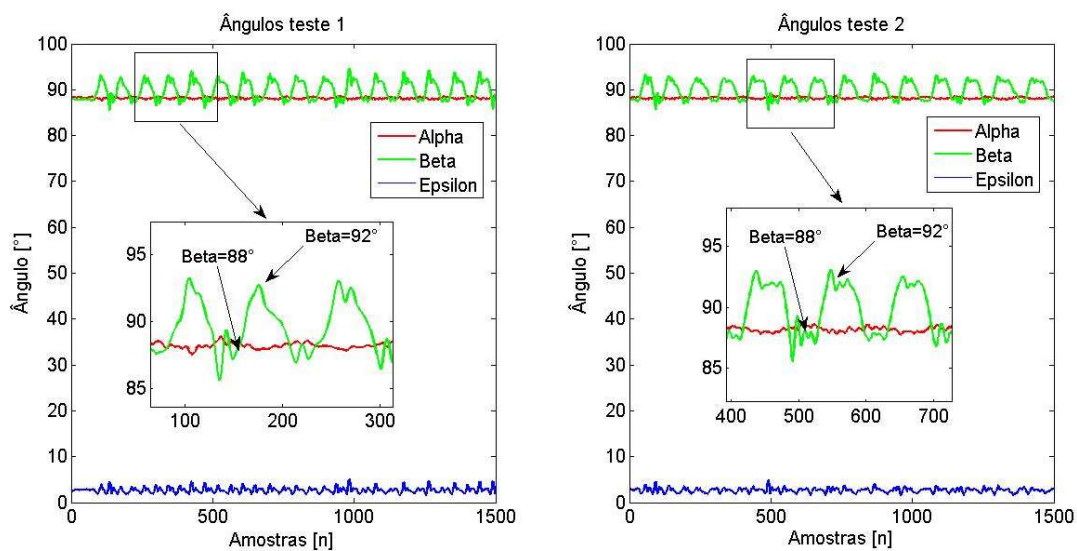
Figura 45 - Ângulos calculados pelo método com o acelerômetro da posição horizontal



Fonte: Elaboração da própria autora.

Os ângulos e parâmetros calculados em dois experimentos realizados com o pêndulo, variando o ângulo  $\beta \cong \pm 4$  estão apresentados na Figura 46 e o deslocamento calculado na Figura 47.

Figura 46- Ângulos calculados no experimento realizado com o pêndulo.




Fonte: Elaboração da própria autora.

Nota-se que o ângulo  $\beta$  varia entre  $88^\circ$  -  $92^\circ$ . Este valor depende da posição do acelerômetro no pêndulo, mas pode-se observar que a variação é de aproximadamente  $4^\circ$ .

Os deslocamentos calculados aplicando as equações deste modelo são de iguais a 14,81 mm e 13,55 no eixo ML, eixo de interesse pois foi o que experimentou o deslocamento no pêndulo.

Os cálculos não são exatos, pelo fato de variar o ângulo manualmente, mas pode-se verificar que tanto o ângulo quanto o deslocamento calculado no eixo ML são aproximados. Outros testes foram realizados mudando a posição do acelerômetro no pêndulo para avaliar a sensibilidade do eixo AP e o resultado foi parecido com o apresentado nas figuras 45 e 46.

Figura 47- Deslocamentos calculados no experimento realizado com o pêndulo




Fonte: Elaboração da própria autora.

### 5.3 AVALIAÇÃO DOS MÉTODOS

Com o objetivo de avaliar o desempenho dos métodos apresentados nesta seção, foi realizada uma coleta de dados com 10 voluntários enquanto usavam o sensor MPU-6050 colado na pele, perto da vertebra L3. A coleta de dados foi realizada com uma taxa de amostragem de 200 Hz. Para aplicar o primeiro método usou-se esta taxa de amostragem e foi aplicado um filtro passa baixos com frequência de corte 55 Hz como indicado em Saunders (2013). Para aplicar o segundo método com os mesmos dados, com o objetivo de comparar resultados, foi realizada uma sub amostragem para reduzir a frequência a 50 Hz e posteriormente foi aplicado um filtro passa baixos com frequência de corte de 5 Hz como indicado em Mayagoitia *et al.* (2002). Tanto a sub amostragem, quanto todos os cálculos necessários em cada método foram implementados em Matlab.


Na Figura 48 e na Figura 49 são apresentadas a acelerações reais nos eixos ML e AP e os valores RMS, obtidos de um homem de 66 anos, com altura 1,60 m. Foi solicitado para este voluntário, ficar parado com os pés separados, com os olhos abertos e os olhos fechados, por 30 s em cada condição.

Figura 48 - Acelerações reais nos eixos ML e AP, na condição OA.



Fonte: Elaboração da própria autora.

Figura 49 - Acelerações reais nos eixos ML e AP, na condição OF.



Fonte: Elaboração da própria autora.

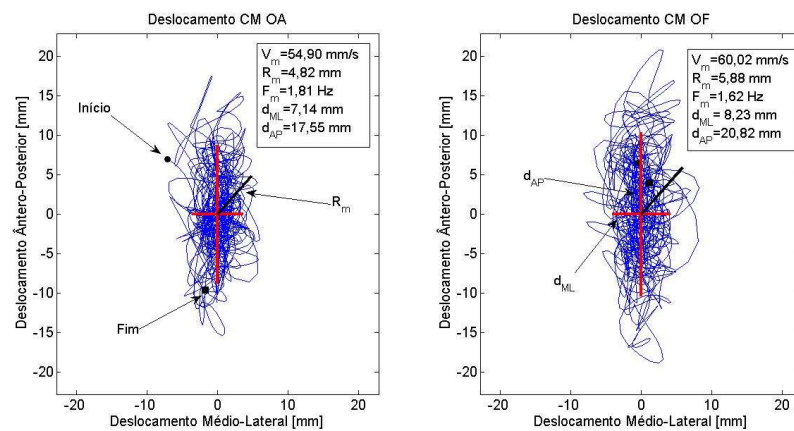
Analisando-se as Figura 48 e Figura 49 pode-se observar que quando o indivíduo fechou os olhos, os valores RMS das acelerações aumentaram, devido a que a segunda condição desafia o sistema de controle postural ao eliminar a visão.

Também se observa que a aceleração no eixo AP é maior quando comparada com a aceleração do eixo ML, o que pode estar relacionado com a separação dos pés que proporciona estabilidade ao indivíduo.

Estes dois fatos estão em concordância com o trabalho de Saunders (2013), onde são apresentados valores de acelerações obtidos nos experimentos, que permitem a comparação com os resultados desta pesquisa.

Na Figura 50 são apresentados os deslocamentos do mesmo indivíduo, assim como os outros parâmetros calculados com o segundo método. Pode-se verificar que todos os valores aumentam na condição OF, excetuando a  $F_m$ , a qual depende de  $R_m$ . Mais uma vez, este aumento de valores dos parâmetros está de acordo com os resultados de Mayagoitia *et al.* (2002) e os valores estão no intervalo dos valores apresentado no mesmo trabalho.

Figura 50 – Deslocamentos e parâmetros calculados nas condições OA e OF.



Fonte: Elaboração da própria autora.

Em Mayagoitia *et al.* (2002) realizou-se uma medição com oito adultos jovens usando o acelerômetro e parados em uma plataforma de força simultaneamente, em quatro condições:

- Posição dos pés confortável, olhos abertos;
- Posição dos pés confortável, olhos fechados;
- Pés juntos, olhos abertos;
- Pés juntos, olhos fechados.

Os autores do trabalho indicam que os valores dos parâmetros calculados com o acelerômetro não foram comparados diretamente com os obtidos com a plataforma de força, pois as medições foram realizadas com transdutores de larguras de banda e referências geométricas diferentes. Com cada dispositivo são aplicadas diferentes aproximações e suposições. Tudo isso leva a que os parâmetros calculados com o acelerômetro sejam maiores devido a que a sensibilidade deste sensor ser maior. Contudo, os parâmetros seguem o mesmo comportamento de condição para condição, tanto numericamente quanto estatisticamente.

Isto também foi observado nesta pesquisa, ao comparar os deslocamentos nos eixos AP e ML calculados com o acelerômetro com os calculados por um

baropodômetro. Este é um aparelho constituído por sensores FSR (*force-sensing resistor*) que como a plataforma de força, permite analisar o deslocamento do CP.

Na Figura 51 é apresentado o procedimento aplicado para coletar os dados, que implicou o uso dos dois dispositivos simultaneamente. As condições avaliadas foram três:

- Postura ereta semi-estática com olhos abertos: OA;
- Postura ereta semi-estática com olhos fechados: OF;
- Postura ereta unipodal: 1P.

Figura 51- Coleta de dados com o acelerômetro e baropodômetro simultaneamente



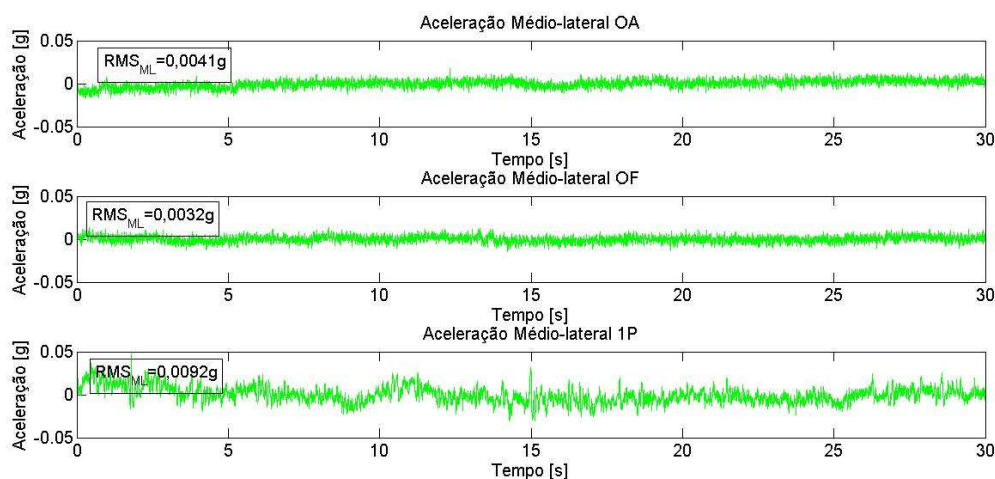
Fonte: Elaboração da própria autora.

Esperava-se um aumento considerável dos parâmetros na terceira condição, devido a diminuição da base de apoio do indivíduo, com o qual a estabilidade diminui.

Nas figuras 52, 53 e 54 são apresentados os resultados dos dois métodos, obtidos com dados coletados de um indivíduo de 35 anos e 1,79 m de altura. Na figura 52 é apresentado o sinal do eixo ML nas três condições avaliadas: OA, OF e 1P. Os valores RMS nas condições OA e OF são semelhantes e de fato o valor na

condição OF diminui quando comparada com a condição OA. Entretanto, o valor da condição 1P apresenta um aumento considerável comparado com as condições OA e OF.

Figura 52 - Acelerações e valores RMS do eixo ML nas condições OA, OF e 1P.




Fonte: Elaboração da própria autora.

Na Figura 53 apresenta-se a aceleração do eixo AP nas três condições avaliadas. Neste eixo, contrário ao observado no eixo ML, nota-se um aumento do valor RMS de condição a condição. Esta situação novamente se associa à separação dos pés adotada no momento de realizar os testes, que permite ao indivíduo ter uma maior estabilidade no eixo ML. Porém é necessário realizar mais testes para poder concluir isto.

Na Figura 54 são apresentados os resultados do segundo método no mesmo teste. Constatase que na medida em que aumenta a dificuldade imposta pela condição avaliada também aumentam os deslocamentos e outros parâmetros calculados com o acelerômetro. Pode-se verificar que no eixo ML a diferença entre os deslocamentos na condição OA e OF é de somente 0.46 mm, enquanto no eixo AP esta diferença é de 3,51 mm, confirmando assim a maior variabilidade neste eixo, como se observou com o outro método. Ao avaliar a condição 1P, nota-se um aumento considerável de todos os parâmetros, quando comparado

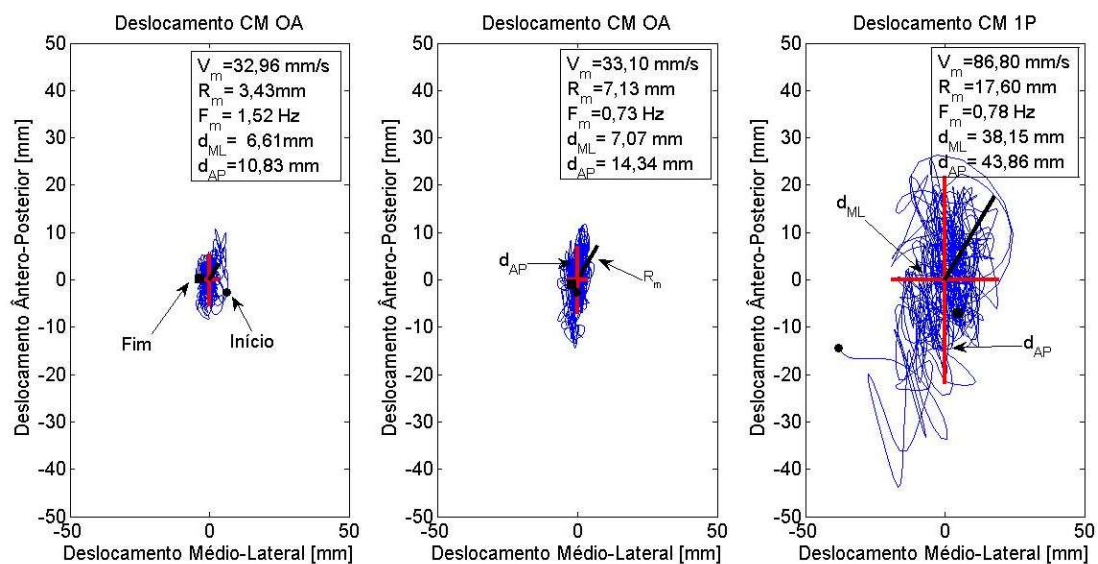
com as condições OA e OF, ratificando-se as semelhanças nos resultados dos dois métodos.

Figura 53 - Acelerações e valores RMS do eixo AP nas condições OA, OF e 1P.



Fonte: Elaboração da própria autora.

Figura 54 – Deslocamentos e parâmetros nas condições OA, OF e 1P.



Fonte: Elaboração da própria autora.

Na Tabela 5 são apresentados os valores obtidos no mesmo teste com o baropodômetro. Como pode-se observar estes valores aumentam junto com a dificuldade da condição avaliada e pode-se constatar que os parâmetros calculados com o acelerômetro são maiores quando comparados com os calculados com o baropodômetro.

Tabela 5 – Parâmetros calculados com o baropodômetro.

	<b>OLHOS ABERTOS</b>	<b>OLHOS FECHADOS</b>	<b>APOIO EM UM PÉ</b>
<b>Velocidade Média Total [mm/s]</b>	6,154	6,4509	18,8811
<b>Amplitude ML [mm]</b>	3,9978	6,1145	11,3075
<b>Amplitude AP [mm]</b>	7,0336	7,4411	20,6856

Fonte: Elaboração da própria autora.

Para poder determinar uma correlação entre os valores obtidos com os dois dispositivos é necessário desenvolver um estudo estatístico com maior número de indivíduos de diferentes grupos (idosos e jovens) e condições (olhos abertos, olhos fechados, pés juntos, pés separados, superfície firme e instável) o que foge do objetivo desta pesquisa. Contudo, pode se concluir que o acelerômetro utilizado consegue diferenciar condições que desafiam o sistema de controle postural e que são usadas para avaliar o equilíbrio na postura ereta semi-estática, com os dois modelos implementados. Desta forma com essa funcionalidade tem-se um sistema prático e de baixo custo quando comparado com plataformas de força.

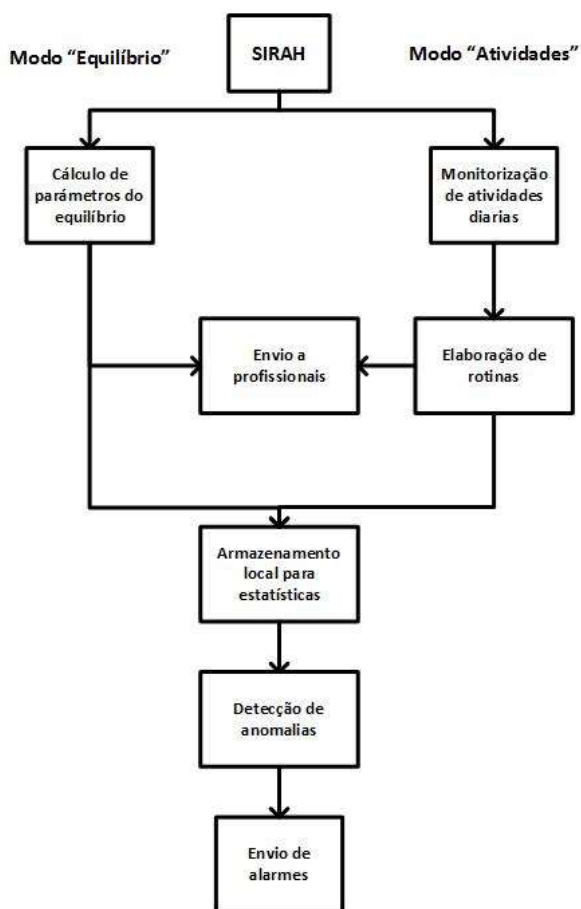
#### 5.4 SIRAH: ABORDAGEM INTEGRADA

Uma vez confirmada a possibilidade de usar o acelerômetro na avaliação da oscilação corporal, é possível propor um sistema que unifique o reconhecimento de atividades e a avaliação do equilíbrio postural em uma

abordagem integrada, apresentada na Figura 55. O sistema SIRAH trabalharia em dois modos: Equilíbrio e Atividades.

Quando o sistema operar no modo “Equilíbrio” solicitará ao usuário permanecer na postura ereta, com os pés separados em posição confortável, enquanto as acelerações são coletadas. O sistema indicará mediante sinais auditivos os tempos em que o usuário deve permanecer com os olhos abertos e fechados, podendo incluir várias tentativas, tentando garantir a integridade do teste. Com estes dados podem ser calculados os parâmetros relacionados com o equilíbrio no computador, para serem armazenados localmente e obter informação estatísticas e/ou serem enviados através da internet.

Figura 55 - SIRAH sistema de reconhecimento de atividades e avaliação do equilíbrio postural



Fonte: Elaboração da própria autora.

Neste modo os cálculos são realizados no computador, o que não representa uma limitante, pois a avaliação do equilíbrio postural não será realizada constantemente, a diferença do reconhecimento de atividades. No entanto, numa futura etapa da pesquisa, esta avaliação poderia ser implementada no próprio sistema, eliminando assim essa restrição do sistema.

Quando o usuário utilizar o sistema SIRAH em modo “Atividades”, as possíveis aplicações são as explicadas na seção 0.

Nos dois casos, se o sistema detectar anomalias em relação ao aumento dos valores relacionados com o equilíbrio postural ou à quantidade (pouca) de atividade realizada pelo usuário, poder ser ativados os alarmes respectivos.

## 6 CONCLUSÃO E TRABALHO FUTURO

A pesquisa apresentada destinou-se a aprofundar teórica e empiricamente a problemática do reconhecimento de atividades humanas e a avaliação do equilíbrio postural.

O reconhecimento de atividades humanas, é uma área que agrupa diversas técnicas de classificação, com o objetivo de identificar padrões do comportamento humano no momento da ocorrência. A identificação é realizada processando dados gerados por sensores localizados no ambiente ou no corpo do usuário.

Neste trabalho projetou-se um sistema de reconhecimento de atividades, com base nos sinais geradas por um acelerômetro localizado na cintura do usuário. O sistema SIRAH pode reconhecer três posturas e quatro atividades de forma eficiente.

No desenvolvimento do sistema SIRAH foram realizadas as duas fases do reconhecimento de atividades. A fase *Offline* e a fase *Online*.

Na fase *Offline*, que trata do treinamento do algoritmo de aprendizagem, realizaram-se vários estudos de caso com diferentes conjuntos de treinamento. No primeiro caso examinou-se a precisão alcançada pela RNA treinada com um conjunto de atributos gerados no domínio do tempo. A precisão foi adequada, com uma classificação correta 94,40% das vezes. Posteriormente analisou-se o impacto do aumento e diversificação dos atributos na precisão, realizando outros dois estudos de caso. Nestes casos geraram-se 34 atributos tanto no domínio do tempo quanto da frequência. Observou-se que nem aumentar o número de atributos nem incluir atributos no domínio da frequência proporcionaram uma melhora significativa na precisão alcançada pelo classificador do primeiro estudo de caso, o que levou a analisar o desempenho desse modelo em cada atividade. A RNA classificou todas as posturas e as atividades caminhar e correr com uma precisão igual a 100%, mas este valor caiu para a atividade sentar-se em 88.8% e levantar-se 73,37%. Uma avaliação dos atributos permitiu constatar que estes

apresentam sobreposição para as duas atividades, devido a que ao ser segmentadas os sinais ficam muito parecidos, pelo que se concluiu que o erro de classificador é inerente a estas duas atividades.

Como trabalho futuro nesta fase *Offline* propõe-se:

- Estudar o efeito da segmentação na classificação, comparando os resultados dos diferentes estudos de caso aplicando janelas tamanhos diferentes, tanto sem sobreposição quanto com sobreposição, para evitar a perda de informação nas uniões dos segmentos;
- Avaliar a Teoria de Ressonância Adaptativa (Adaptative Resonance Theory, ART) para reconhecimento de padrões e as vantagens que apresenta frente as RNA MLP (Multy Layer Perceptron). As redes MLP não podem aprender sucessivamente amenos que sejam treinadas novamente com a informação antiga e a nova. Por outro lado, as redes ART e suas variações como por exemplo, ARTMAP, podem aprender novos padrões sem esquecer os já aprendidos no passado o que resulta interessante e conveniente no reconhecimento de atividades de atividades humanas, pois o sistema poderia ser constantemente treinado, tomando em conta a variabilidade com que o ser humano realiza as atividades no decorrer do tempo;
- Gerar outros atributos que permitam diferenciar de forma mais precisa as atividades sentar-se e levantar-se, onde se observou o pior desempenho do classificador. Entre estes atributos está por exemplo, o ângulo de inclinação;
- Avaliar a possível inserção de um giroscópio no sistema SIRAH. No trabalho de Shoaib *et al.*, (2013) foram comparados vários algoritmos de classificação treinados com atributos gerados no domínio do tempo a partir dos sinais de um acelerômetro e de um giroscópio embutidos em um smartphone. Os autores treinaram os algoritmos com atributos do acelerômetro e do giroscópio independentemente;

depois treinaram os algoritmos com os atributos dos dois sensores. Na maioria dos casos demonstrou-se que os dois sensores se complementam no reconhecimento de atividades, apresentando uma maior precisão quando usados de maneira conjunta. Desta forma, implementar a classificação de atividades com os dois sensores incluído no módulo MPU-6050 representa uma opção que poderia melhorar o desempenho do sistema SIRAH e que vale a pena ser avaliada.

Na fase *Online* implementou-se em um microcontrolador os processos de filtragem, geração e normalização de atributos, assim como o modelo obtido no treinamento do primeiro estudo de caso. Desta forma tem-se um sistema portátil e confortável que pode classificar as três posturas e quatro atividades em tempo real.

Entre as aplicações para este sistema mencionaram-se a monitorização da quantidade de atividade que realiza uma pessoa diariamente e a identificação de tempos longos de inatividade. Na fase *Online* do sistema SIRAH, resulta importante no futuro:

- Validar a classificação *Online* realizando testes em ambientes não supervisionados;
- Implementar o sistema SIRAH em um FPGA, dispositivo que permite execução em paralelo, o que será aproveitado para aumentar a velocidade de processamento das acelerações dos três eixos do sensor;
- Analisar as transições entre posturas para melhorar a precisão na classificação das atividades como sentar-se e levantar-se.

Além do reconhecimento de atividades, o sistema SIRAH calcula parâmetros relacionados com a oscilação postural na postura ereta semi-estática. A capacidade de manter o equilíbrio postural diminui com o processo de envelhecimento e algumas doenças, deixando a pessoa com maior risco de sofrer

quedas. Neste cenário, a aplicação do sistema SIRAH torna-se uma ferramenta interessante para análise e quantificação da oscilação corporal, além de monitorar pacientes em casa e ambientes clínicos.

Na avaliação do equilíbrio postural foram estudados dois métodos. O primeiro corrige a inclinação do acelerômetro para obter as acelerações horizontais do CM nos eixos AP e ML, assim como os valores RMS. O segundo método calcula cinco parâmetros do CM: velocidade média, raio médio, frequência média e deslocamentos nos eixos AP e ML. Foram realizados vários testes que permitiram demonstrar a capacidade dos métodos para diferenciar condições utilizadas na avaliação do equilíbrio postural.

Nesta funcionalidade do sistema SIRAH o trabalho futuro estará focado em:

- Realizar testes com maior quantidade de pessoas e mais condições, com o objetivo de encontrar uma correlação entre os parâmetros calculados com o acelerômetro e com o baropodômetro;
- Avaliar a pertinência da implementação da avaliação do equilíbrio postural no próprio sistema, eliminando a transmissão das acelerações até o computador;
- Avaliar a implementação do filtro Kalman com os dados do acelerômetro e giroscópio localizados na região L3 para caracterizar o equilíbrio postural. No trabalho de Jawad *et al.* (2013), os autores utilizaram o filtro Kalman para estimar a orientação do corpo e com esta estimação calcularam a trajetória do CM em diferentes condições. Os autores reportaram um incremento nos deslocamentos do CM na medida em que a dificuldade imposta pela condição medida aumentava. Porém não foi realizada a comparação com uma plataforma de força devido a indisponibilidade do aparelho. Contudo, tomando em conta que o filtro Kalman realiza a fusão dos sensores corrigindo o *drift* do giroscópio e atenuando o ruído do acelerômetro, que permite calcular uma estimativa robusta. Acredita-

se que este é um método interessante e que deve também ser pesquisado para comparar com os resultados já obtidos;

- Estudar outros métodos de avaliação do equilíbrio postural, por exemplo os testes *Timed up and go* e a Escala de Equilíbrio de Berg, para analisar as acelerações geradas nas tarefas de cada método, buscando possíveis correlações com acelerômetro e poder implementar assim novas aplicações clínicas e de monitoramento remoto do sistema SIRAH.

## REFERÊNCIAS

- ACAMPORA, G. et al. A survey on ambient intelligence in healthcare. **Proceedings of the IEEE**, New York, v. 101, n. 12, p. 2470-2494, Dec 2013. ISSN: 0018-9219 DOI: 10.1109/JPROC.2013.2262913.
- AHMED, E. et al. Internet-of-things-based smart environments: state of the art, taxonomy, and open research challenges. **IEEE Wireless Communications**, Piscataway, v. 23, n. 5, p. 10-16, October 2016. ISSN: 1536-1284 DOI: 10.1109/MWC.2016.7721736.
- AL-JAWAD, A. et al. The use of an orientation kalman filter for the static postural sway analysis. **APCBEE Procedia**, Amsterdam, v. 7, p. 93-102, 2013. ISSN: 2212-6708. DOI: <http://dx.doi.org/10.1016/j.apcbee.2013.08.018>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2212670813001206>>. Acesso em: 28 abr. 2014.
- ALSHURAF, N. et al. Designing a robust activity recognition framework for health and exergaming using wearable sensors. **IEEE Journal of Biomedical and Health Informatics**, Piscataway, v. 18, n. 5, p. 1636-1646, Sept 2014. ISSN: 2168-2194 DOI: 10.1109/JBHI.2013.2287504.
- ANDRIES, M.; SIMONIN, O.; CHARPILLET, F. Localization of humans, objects, and robots interacting on load-sensing floors. **IEEE Sensors Journal**, Piscataway, v. 16, n. 4, p. 1026-1037, Feb 2016. ISSN: 1530-437X DOI: 10.1109/JSEN.2015.2493122.
- ANGUITA, D. et al. Energy efficient smartphone-based activity recognition using fixed-point arithmetic. **Journal of Universal Computer Science**, Graz, v. 19, n. 9, p. 1295-1314, may 2013.
- [http://www.jucs.org/jucs\\_19\\_9/energy\\_efficient\\_smartphone\\_based/](http://www.jucs.org/jucs_19_9/energy_efficient_smartphone_based/).
- ARIF, M. et al. Better physical Activity Classification using smartphone acceleration sensor. **Journal of Medical Systems**, New York, v. 38, n. 9, p. 95, 2014. ISSN: 1573-689X DOI: 10.1007/s10916-014-0095-0. Disponível em: <<http://dx.doi.org/10.1007/s10916-014-0095-0>>. Acesso em: 28 abr. 2014.
- AUGUSTO, J. C. et al. Intelligent environments: a manifesto. **Human-centric Computing and Information Sciences**, Heidelberg, v. 3, n. 1, p. 12, 2013. ISSN: 2192-1962 DOI: 10.1186/2192-1962-3-12. Disponível em: <<http://dx.doi.org/10.1186/2192-1962-3-12>>. Acesso em: 28 abr. 2014.

BAEK, J. et al. Accelerometer Signal Processing for User Activity Detection. In: NEGOITA, M. G.; HOWLETT, R. J.; JAIN, L. C. In: INTERNATIONAL CONFERENCE, 8th., 2004, Wellington. **Proceedings...** Berlin: Springer Berlin Heidelberg, 2004. p. 610-617. ISBN: 978-3-540-30134-9 DOI: 10.1007/978-3-540-30134-9\_82. Disponível em: <[http://dx.doi.org/10.1007/978-3-540-30134-9\\_82](http://dx.doi.org/10.1007/978-3-540-30134-9_82)>. Acesso em: 28 abr. 2014.

BANERJEE, T. et al. Day or Night Activity Recognition From Video Using Fuzzy Clustering Techniques. **IEEE Transactions on Fuzzy Systems**, Piscataway, v. 22, n. 3, p. 483-493, June 2014. ISSN: 1063-6706 DOI: 10.1109/TFUZZ.2013.2260756.

BASTERRETXEA, K.; ECHANOBÉ, J.; DEL CAMPO, I. A wearable human activity recognition system on a chip. In: CONFERENCE ON DESIGN AND ARCHITECTURES FOR SIGNAL AND IMAGE, 2014, [S. l.] **Proceedings...** [S.l.: s.n.], 2014. p. 1-8.

BEILY, M. D. E. et al. A sensor based on recognition activities using smartphone. In: INTERNATIONAL SEMINAR ON INTELLIGENT TECHNOLOGY AND ITS APPLICATIONS (ISITIA), 2016, [S. l.] **Proceedings...** [S.l.: s. n.], 2016. p. 393-398.

BISIO, I. et al. Enabling IoT for In-Home Rehabilitation: Accelerometer signals classification methods for activity and movement recognition. **IEEE Internet of Things Journal**, Piscataway, v. PP, n. 99, p. 1-1, 2016. ISSN: 2327-4662 DOI: 10.1109/JIOT.2016.2628938.

BULLING, A.; BLANKE, U.; SCHIELE, B. A Tutorial on human activity recognition using body-worn inertial sensors. **ACM Comput. Surv.**, New York, v. 46, n. 3, p. 33:1--33:33, #jan# 2014. ISSN: 0360-0300 DOI: 10.1145/2499621. Disponível em: <<http://doi.acm.org/10.1145/2499621>>. Acesso em: 28 abr. 2014.

CAPELA, N. A. A. L. E. D. A. B. N. Feature selection for wearable smartphone-based human activity recognition with able bodied, elderly, and stroke patients. **PLOS ONE**, v. 10, n. 4, p. 1-18, abr. 2015. ISSN DOI: 10.1371/journal.pone.0124414. Disponível em: <<http://dx.doi.org/10.1371%2Fjournal.pone.0124414>>. Acesso em: 15 mar. 2017.

CHEN, Y.; XUE, Y. A deep learning approach to human activity recognition based on single accelerometer. In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS, 2015, [S. l.] **Proceedings...** [S.l.: s.n.], 2015. p. 1488-1492.

CHENG, J. et al. Designing Sensitive Wearable Capacitive Sensors for Activity Recognition. **IEEE Sensors Journal**, Piscataway, v. 13, n. 10, p. 3935-3947, Oct 2013. ISSN: 1530-437X DOI: 10.1109/JSEN.2013.2259693.

CHUN, S.; LEE, C. S. Human action recognition using histogram of motion intensity and direction from multiple views. **IET Computer Vision**, Stevenage, v. 10, n. 4, p. 250-256, 2016. ISSN: 1751-9632 DOI: 10.1049/iet-cvi.2015.0233.

COOK, D. J.; AUGUSTO, J. C.; JAKKULA, V. R. Ambient intelligence: technologies, applications, and opportunities. **Pervasive and Mobile Computing**, Amsterdam, v. 5, n. 4, p. 277-298, 2009. ISSN: 1574-1192 DOI: 10.1016/j.pmcj.2009.04.001. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S157411920900025X>>. Acesso em: 20 mar. 2013.

CORNACCHIA, M. et al. A Survey on activity detection and classification using wearable sensors. **IEEE Sensors Journal**, Piscataway, v. 17, n. 2, p. 386-403, Jan 2017. ISSN: 1530-437X DOI: 10.1109/JSEN.2016.2628346.

COSTILLA-REYES, O.; SCULLY, P.; OZANYAN, K. B. Temporal pattern recognition in gait activities recorded with a footprint imaging sensor system. **IEEE Sensors Journal**, Piscataway, v. 16, n. 24, p. 8815-8822, Dec 2016. ISSN: 1530-437X DOI: 10.1109/JSEN.2016.2583260.

DA SILVA, F. G.; GALEAZZO, E. Accelerometer based intelligent system for human movement recognition. In: IEEE INTERNATIONAL WORKSHOP ON ADVANCES IN SENSORS AND INTERFACES IWASI, 5th, 2013, [S. l.]. **Proceedings...** [S.l.: s.n.], 2013. p. 20-24.

DAHER, M. et al. Elder tracking and fall detection system using smart tiles. **IEEE Sensors Journal**, Piscataway, v. 17, n. 2, p. 469-479, Jan 2017. ISSN: 1530-437X DOI: 10.1109/JSEN.2016.2625099.

DE, D. et al. Multimodal wearable sensing for fine-grained activity recognition in healthcare. **IEEE Internet Computing**, Piscataway, v. 19, n. 5, p. 26-35, Sept 2015. ISSN: 1089-7801 DOI: 10.1109/MIC.2015.72.

DOHERTY, A. R. et al. Using wearable cameras to categorise type and context of accelerometer-identified episodes of physical activity. **International Journal of Behavioral Nutrition and Physical Activity**, London, v. 10, n. 1, p. 22, 2013. ISSN: 1479-5868 DOI: 10.1186/1479-5868-10-22. Disponível em: <<http://dx.doi.org/10.1186/1479-5868-10-22>>. Acesso em: 28 jan. 2017.

DUARTE, M. A. F. S. M. S. F. Revisão sobre posturografia baseada em plataforma de força para avaliação do equilíbrio. **Brazilian Journal of Physical Therapy**, Sao Carlos, v. 14, p. 183-192, jun. 2010. ISSN: 1413-3555. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1413-35552010000300003&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-35552010000300003&nrm=iso)>. Acesso em: 15 fev. 2017.

ERDEN, F. et al. Sensors in Assisted Living: A survey of signal and image processing methods. **IEEE Signal Processing Magazine**, Piscataway, v. 33, n. 2, p. 36-44, March 2016. ISSN: 1053-5888 DOI: 10.1109/MSP.2015.2489978.

ERDEN, F.; ÇETIN, A. E. Hand gesture based remote control system using infrared sensors and a camera. **IEEE Transactions on Consumer Electronics**, Piscataway, v. 60, n. 4, p. 675-680, Nov 2014. ISSN: 0098-3063 DOI: 10.1109/TCE.2014.7027342.

FORTIN-SIMARD, D. et al. Exploiting Passive RFID Technology for Activity Recognition in Smart Homes. **IEEE Intelligent Systems**, Piscataway, v. 30, n. 4, p. 7-15, July 2015. ISSN: 1541-1672 DOI: 10.1109/MIS.2015.18.

FORTUNE, E. et al. Activity level classification algorithm using SHIMMER wearable sensors for individuals with rheumatoid arthritis. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2011, [S. I.]. **Proceedings...** [S.I.: s.n.], 2011. p. 3059-3062.

GAGLIO, S.; RE, G. L.; MORANA, M. Human activity recognition process using 3-d posture data. **IEEE Transactions on Human-Machine Systems**, Piscataway, v. 45, n. 5, p. 586-597, Oct 2015. ISSN: 2168-2291 DOI: 10.1109/THMS.2014.2377111.

GUPTA, P.; DALLAS, T. Feature Selection and Activity Recognition System Using a Single Triaxial Accelerometer. **IEEE Transactions on Biomedical Engineering**, Piscataway, v. 61, n. 6, p. 1780-1786, June 2014. ISSN: 0018-9294 DOI: 10.1109/TBME.2014.2307069.

HAJIHASHEMI, Z.; YEFIMOVA, M.; POPESCU, M. Detecting daily routines of older adults using sensor time series clustering. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 36th, 2014, [S. I.]. **Proceedings...** [S.I.: s.n.]. 2014. p. 5912-5915.  
HAN, J.; KAMBER, M. **Data mining concepts and techniques**. [S.I.]: Morgan Kaufmann, 2006.

HAYKIN, S. **Redes neurais princípios e prática**. [S.I.]: Prentice Hall, 1999.  
HONG, Y. J. et al. Activity recognition using wearable sensors for elder care. In: INTERNATIONAL CONFERENCE ON FUTURE GENERATION COMMUNICATION AND NETWORKING, 2., 2008, [S. I.]. **Proceedings...** [S.I.: s.n.]. Dec 2008. p. 302-305.

HONG, Y.-J. et al. Mobile health monitoring system based on activity recognition using accelerometer. **Simulation Modelling Practice and Theory**, Amsterdam, v. 18, n. 4, p. 446-455, 2010. ISSN: 1569-190X DOI: <http://dx.doi.org/10.1016/j.simpat.2009.09.002>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1569190X09001269>. Acesso em: 28 abr. 2014.

ISLAM, S. M. R. et al. The Internet of Things for Health Care: A Comprehensive Survey. **IEEE Access**, Piscataway, v. 3, p. 678-708, 2015. ISSN: 2169-3536 DOI: 10.1109/ACCESS.2015.2437951. Acesso em: 5 jan. 2017.

JIA, R.; LIU, B. Human daily activity recognition by fusing accelerometer and multi-lead ECG data. In: IEEE INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING, COMMUNICATION AND COMPUTING (ICSPCC 2013), 2013, [S. l.]. **Proceedings...** [S.l.: s.n.], 2013. p. 1-4.

KAILAS, A. Basic human motion tracking using a pair of gyro + accelerometer MEMS devices. In: IEEE INTERNATIONAL CONFERENCE ON E-HEALTH NETWORKING, APPLICATIONS AND SERVICES (HEALTHCOM), 14th, 2012, [S. l.]. **Proceedings...** [S.l.: s. n.], 2012. p. 298-302.

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**, Piscataway, v. 10, n. 1, p. 156-167, 2006. ISSN: 1089-7771 DOI: 10.1109/TITB.2005.856864.

KWAPISZ, J. R.; WEISS, G. M.; MOORE, S. A. Activity recognition using cell phone accelerometers. **SIGKDD Explor. Newsl.**, New York, v. 12, n. 2, p. 74-82, #mar# 2011. ISSN: 1931-0145 DOI: 10.1145/1964897.1964918. Disponível em: <http://doi.acm.org/10.1145/1964897.1964918>. Acesso em: 10 mar. 2017.

LARA, O. D.; LABRADOR, M. A. A Survey on Human Activity Recognition using Wearable Sensors. **IEEE Communications Surveys Tutorials**, Piscataway, v. 15, n. 3, p. 1192-1209, Third 2013. ISSN: 1553-877X DOI: 10.1109/SURV.2012.110112.00192.

LI, M. et al. Multimodal Physical Activity Recognition by Fusing Temporal and Cepstral Information. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, Piscataway, v. 18, n. 4, p. 369-380, 2010. ISSN: 1534-4320 DOI: 10.1109/TNSRE.2010.2053217.

LIN, C. W. et al. A Wearable Sensor Module With a Neural-Network-Based Activity Classification Algorithm for Daily Energy Expenditure Estimation. **IEEE Transactions on Information Technology in Biomedicine**, Piscataway, v. 16, n. 5, p. 991-998, Sept 2012. ISSN: 1089-7771 DOI: 10.1109/TITB.2012.2206602.

LUBINA, P.; RUDZKI, M. Artificial neural networks in accelerometer-based human activity recognition. In: INTERNATIONAL CONFERENCE MIXED DESIGN OF INTEGRATED CIRCUITS SYSTEMS (MIXDES), 22nd, 2015, [S. I.].

**Proceedings...** [S.l.: s.n.], 2015. p. 63-68.

MANNINI, A.; SABATINI, A. M. On-line classification of human activity and estimation of walk-run speed from acceleration data using support vector machines. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2011, [S. I.].

**Proceedings...** [S.l.: s. n.], 2011. p. 3302-3305.

MARGARITO, J. et al. User-Independent Recognition of Sports Activities From a Single Wrist-Worn Accelerometer: A Template-Matching-Based Approach. **IEEE Transactions on Biomedical Engineering**, Piscataway, v. 63, n. 4, p. 788-796, April 2016. ISSN: 0018-9294 DOI: 10.1109/TBME.2015.2471094.

MATHIE, M. J. et al. Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement. **Physiological Measurement**, Bristol, v. 25, n. 2, p. R1, 2004. Disponível em: <<http://stacks.iop.org/0967-3334/25/i=2/a=R01>>. Acesso em: 28 abr. 2014.

MAURER, U. et al. Location and Activity Recognition Using eWatch: A Wearable Sensor Platform. In: CAI, Y.; ABASCAL, J. **Ambient Intelligence in Everyday Life**. [S.I.]: Springer Berlin Heidelberg, v. 3864, 2006. p. 86-102. ISBN ISBN: 978-3-540-37785-6 DOI: 10.1007/11825890\_4. Disponível em: <[http://dx.doi.org/10.1007/11825890\\_4](http://dx.doi.org/10.1007/11825890_4)>. Acesso em: 20 jun. 2016.

MAYAGOITIA, R. E. et al. Standing balance evaluation using a triaxial accelerometer. **Gait & Posture**, v. 16, n. 1, p. 55-59, 2002. ISSN: 0966-6362 DOI: [http://dx.doi.org/10.1016/S0966-6362\(01\)00199-0](http://dx.doi.org/10.1016/S0966-6362(01)00199-0). Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0966636201001990>>. Acesso em: 02 nov. 2017.

MCCARTHY, M. W. et al. Decision-tree-based human activity classification algorithm using single-channel foot-mounted gyroscope. **Electronics Letters**, Stevenage, v. 51, n. 9, p. 675-676, 2015. ISSN: 0013-5194 DOI: 10.1049/el.2015.0436.

MIN, C. H.; INCE, N. F.; TEWFIK, A. H. Generalization capability of a wearable early morning activity detection system. In: EUROPEAN SIGNAL PROCESSING CONFERENCE, 15th, 2007, [S. I.]. **Proceedings...** [S.l.: s.n.], 2007. p. 1556-1560.

MIN, C. H.; INCE, N. F.; TEWFIK, A. H. Classification of continuously executed early morning activities using wearable wireless sensors. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 20th, 2008, [S. I.]. **Proceedings...** [S.l.: s.n.], 2008. p. 5192-5195.

MIN, C. H.; INCE, N. F.; TEWFIK, A. H. Early morning activity detection using acoustics and wearable wireless sensors. In: EUROPEAN SIGNAL PROCESSING CONFERENCE, 16th, 2008, [S. l.]. **Proceedings...** [S.l.: s.n.]. 2008. p. 1-5.

MIN, J. K.; CHO, S. B. Activity recognition based on wearable sensors using selection/fusion hybrid ensemble. In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS, 2011, [S. l.]. **Proceedings...** [S. l.:s. n.], 2011. p. 1319-1324.

MOE-NILSSEN, R.; HELBOSTAD, J. L. Trunk accelerometry as a measure of balance control during quiet standing. **Gait & Posture**, Amsterdam, v. 16, n. 1, p. 60-68, 2002. ISSN: 0966-6362 DOI: 10.1016/S0966-6362(01)00200-4. Disponível em: <[http://dx.doi.org/10.1016/S0966-6362\(01\)00200-4](http://dx.doi.org/10.1016/S0966-6362(01)00200-4)>. Acesso em: 28 abr. 2014.

MOHANTY, S. P.; CHOPPALI, U.; KOUGIANOS, E. Everything you wanted to know about smart cities: The Internet of things is the backbone. **IEEE Consumer Electronics Magazine**, New York, v. 5, n. 3, p. 60-70, July 2016. ISSN: 2162-2248 DOI: 10.1109/MCE.2016.2556879.

NAM, Y.; RHO, S.; LEE, C. Physical activity recognition using multiple sensors embedded in a wearable device. **ACM Trans. Embed. Comput. Syst.**, New York, NY, USA, v. 12, n. 2, p. 26:1--26:14, #feb# 2013. ISSN: 1539-9087 DOI: 10.1145/2423636.2423644. Disponível em: <<http://doi.acm.org/10.1145/2423636.2423644>>. Acesso em: 28 abr. 2014.

PANNURAT, N.; THIEMJARUS, S.; NANTAJEEWARAWAT, E. A hybrid temporal reasoning framework for fall monitoring. **IEEE Sensors Journal**, v. PP, n. 99, p. 1-1, 2017. ISSN: 1530-437X DOI: 10.1109/JSEN.2017.2649542.

PARADA, R. et al. Using RFID to Detect Interactions in Ambient Assisted Living Environments. **IEEE Intelligent Systems**, Piscataway, v. 30, n. 4, p. 16-22, July 2015. ISSN: 1541-1672 DOI: 10.1109/MIS.2015.43.

PEARSON, K. On Lines and Planes of Closest Fit to Systems of Points in Space. **Philosophical Magazine**, Abingdon, v. 2, n. 11, p. 559-572, 1901.

PERERA, C.; LIU, C. H.; JAYAWARDENA, S. The emerging internet of things marketplace from an industrial perspective: a survey. **IEEE Transactions on Emerging Topics in Computing**, Piscataway, v. 3, n. 4, p. 585-598, Dec 2015. ISSN: 2168-6750 DOI: 10.1109/TETC.2015.2390034.

PREECE, S. J. et al. A Comparison of feature extraction methods for the classification of dynamic activities from accelerometer data. **IEEE Transactions on Biomedical Engineering**, Piscataway, v. 56, n. 3, p. 871-879, March 2009. ISSN: 0018-9294 DOI: 10.1109/TBME.2008.2006190.

PREECE, S. J. et al. Activity identification using body-mounted sensors—a review of classification techniques. **Physiological Measurement**, Bristol, v. 30, n. 4, p. R1, 2009. Disponível em: <<http://stacks.iop.org/0967-3334/30/i=4/a=R01>>. Acesso em: 28 abr. 2014.

RAFIQ, G. et al. What's new in intelligent transportation systems?: an overview of european projects and initiatives. **IEEE Vehicular Technology Magazine**, Piscataway, v. 8, n. 4, p. 45-69, Dec 2013. ISSN: 1556-6072 DOI: 10.1109/MVT.2013.2281660.

RAVI, N. et al. Activity recognition from accelerometer data. In: CONFERENCE ON INNOVATIVE APPLICATIONS OF ARTIFICIAL INTELLIGENCE, 17th, 2005, [S. l.]. **Proceedings...** [S.l.]: AAAI, 2005. p. 1541-1546.

RUSSELL, S. . N. P. **Artificial Intelligence: a modern approach**. [S.l.]: [s.n.], 2009.

SAFADI, E. A. et al. Generalized activity recognition using accelerometer in wearable devices for IoT applications. In: IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), 13th, 2016, [S.l.]. **Proceedings...** [S. l.: s.n.], 2016. p. 73-79.

SAUNDERS, N. W. **Reliability and validity of an accelerometer-based balance assessment for fall risk screening**. Ohio: The Ohio State University, 2013.

SERRA, R. et al. Activity Recognition With Smart Polymer Floor Sensor: Application to Human Footstep Recognition. **IEEE Sensors Journal**, Piscataway, v. 16, n. 14, p. 5757-5775, 2016. ISSN: 1530-437X DOI: 10.1109/JSEN.2016.2554360.

SHIMOKAWARA, E. et al. Estimation of basic activities of daily living using zigbee 3d accelerometer sensor network. In: INTERNATIONAL CONFERENCE ON BIOMETRICS AND KANSEI ENGINEERING, 2013, [S. l.]. **Proceedings...** [S.l.: s. n.], 2013. p. 251-256.

SHOAB, M.; SCHOLTEN, H.; HAVINGA, P. J. M. Towards physical activity recognition using smartphone sensors. In: IEEE INTERNATIONAL CONFERENCE ON UBIQUITOUS INTELLIGENCE AND COMPUTING, 10th., 2013, [S. l.]. **Proceedings...** [S.l.: s.n.], 2013. p. 80-87.

SKUBIC, M.; GUEVARA, R. D.; RANTZ, M. Automated health alerts using in-home sensor data for embedded health assessment. **IEEE Journal of Translational Engineering in Health and Medicine**, New York, v. 3, p. 1-11, 2015. ISSN: 2168-2372 DOI: 10.1109/JTEHM.2015.2421499.

SOARES, A. V. A contribuição visual para o controle postural. **Revista Neurociências**, São Paulo, v. 18, p. 370-379, 2010.

SURYADEVARA, N. K.; MUKHOPADHYAY, S. C. Determining wellness through an ambient assisted living environment. **IEEE Intelligent Systems**, Piscataway, v. 29, n. 3, p. 30-37, May 2014. ISSN: 1541-1672 DOI: 10.1109/MIS.2014.16.

TAPIA, E. M. et al. Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart rate monitor. In: IEEE INTERNATIONAL SYMPOSIUM ON WEARABLE COMPUTERS, 11th, 2007, [S. l.]. **Proceedings...** [S.l.: s.n.], 2007. p. 37-40.

TEIXEIRA, C. Equilíbrio e controle postural. **Brazilian Journal of Biomechanics = Revista Brasileira de Biomecânica**, São Paulo, v. 11, n. 20, 2013. ISSN: 1983-2710. Disponível em: <<http://citrus.uspnet.usp.br/biomecan/ojs/index.php/rbb/article/view/151>>. Acesso em: 20 jan 2017.

TORRES, R. L. S. et al. Sensor enabled wearable RFID technology for mitigating the risk of falls near beds. In: IEEE INTERNATIONAL CONFERENCE ON RFID (RFID), 2013, [S. l.]. **Proceedings...** [S. l.: s. n.], 2013. p. 191-198.

WANG, B. et al. Laplacian LRR on Product Grassmann Manifolds for Human Activity Clustering in Multi-Camera Video Surveillance. **IEEE Transactions on Circuits and Systems for Video Technology**, Piscataway, v. PP, n. 99, p. 1-1, 2016. ISSN: 1051-8215 DOI: 10.1109/TCSVT.2016.2609760.

WANG, J.-S. et al. A PACE Sensor system with machine learning-based energy expenditure regression algorithm. In: HUANG, D.-S. et al. **Bio-inspired computing and applications**. Heidelberg: Springer Berlin Heidelberg, 2012. p. 529-536. ISBN: 978-3-642-24553-4 DOI: 10.1007/978-3-642-24553-4\_70. Disponível em: <[http://dx.doi.org/10.1007/978-3-642-24553-4\\_70](http://dx.doi.org/10.1007/978-3-642-24553-4_70)>. Acesso em: 20 maio. 2015.

WANG, L. et al. Toward a Wearable RFID System for Real-Time Activity Recognition Using Radio Patterns. **IEEE Transactions on Mobile Computing**, Piscataway, v. 16, n. 1, p. 228-242, Jan 2017. ISSN: 1536-1233 DOI: 10.1109/TMC.2016.2538230.

WANG, S. et al. Human activity recognition with user-free accelerometers in the sensor networks. IN: INTERNATIONAL CONFERENCE ON, ICNN B '05, 2005, [S. l.]. **Proceedings...** [S. l.: s. n.], 2005. p. 1212-1217.

WANG, Z. et al. A Triaxial Accelerometer-Based Human Activity Recognition via EEMD-Based Features and Game-Theory-Based Feature Selection. **IEEE Sensors Journal**, Piscataway, v. 16, n. 9, p. 3198-3207, May 2016. ISSN: 1530-437X DOI: 10.1109/JSEN.2016.2519679.

WANNENBURG, J.; MALEKIAN, R. Physical activity recognition from smartphone accelerometer data for user context awareness sensing. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, Piscataway, v. PP, n. 99, p. 1-8, 2016. ISSN: 2168-2216 DOI: 10.1109/TSMC.2016.2562509.

WEISER, M. The computer for the 21st century. **SIGMOBILE Mob. Comput. Commun. Rev.**, New York, v. 3, n. 3, p. 3-11, 1999. ISSN: 1559-1662 DOI: 10.1145/329124.329126. Disponível em: <<http://doi.acm.org/10.1145/329124.329126>>. Acesso em: 06 mar. 2013.

WU, H. H.; LEMAIRE, E. D.; BADDOUR, N. Change-of-state determination to recognize mobility activities using a BlackBerry smartphone. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2011, [S. l.]. **Proceedings...** [S. l.: s. n.], 2011. p. 5252-5255.

WUJCIK, E. K. et al. Ion Sensor for the Quantification of Sodium in Sweat Samples. **IEEE Sensors Journal**, Piscataway, v. 13, n. 9, p. 3430-3436, Sept 2013. ISSN: 1530-437X DOI: 10.1109/JSEN.2013.2257168.

YACHIR, A. et al. Event-Aware Framework for Dynamic Services Discovery and Selection in the Context of Ambient Intelligence and Internet of Things. **IEEE Transactions on Automation Science and Engineering**, Piscataway, v. 13, n. 1, p. 85-102, Jan 2016. ISSN: 1545-5955 DOI: 10.1109/TASE.2015.2499792.

YANG, X.; TIAN, Y. Super normal vector for human activity recognition with depth cameras. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Piscataway, v. PP, n. 99, p. 1-1, 2016. ISSN: 0162-8828 DOI: 10.1109/TPAMI.2016.2565479.

YAZAR, A. et al. Fall detection using single-tree complex wavelet transform. **Pattern Recogn. Lett.**, New York, v. 34, n. 15, p. 1945-1952, #nov# 2013. ISSN: 0167-8655 DOI: 10.1016/j.patrec.2012.12.010. Disponível em: <<http://dx.doi.org/10.1016/j.patrec.2012.12.010>>. Acesso em: 15 fev. 2017.

ZHAN, K.; FAUX, S.; RAMOS, F. Multi-scale conditional random fields for first-person activity recognition on elders and disabled patients. **Pervasive and Mobile Computing**, Amsterdam, v. 16, Part B, p. 251-267, 2015. ISSN: 1574-1192 DOI: <http://dx.doi.org/10.1016/j.pmcj.2014.11.004>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1574119214001850>>. Acesso em: 20 nov. 2016.

ZHANG, S. et al. Activity monitoring using a smart phone's accelerometer with hierarchical classification. In: INTERNATIONAL CONFERENCE ON INTELLIGENT ENVIRONMENTS, 2010, [S. l.]. **Proceedings...** [S. l.: s. n.], 2010. p. 158-163.

ZHOU, B. et al. Smart table surface: a novel approach to pervasive dining monitoring. In: IEEE INTERNATIONAL CONFERENCE ON PERVASIVE COMPUTING AND COMMUNICATIONS (PERCOM), 2015, [S. l.]. **Proceedings...** [S.l.: s. n.], 2015. p. 155-162.