

FERNANDO GINEZ DA SILVA

Reconhecimento de movimentos humanos utilizando um acelerômetro e  
inteligência computacional

São Paulo  
2013

FERNANDO GINEZ DA SILVA

Reconhecimento de movimentos humanos utilizando um acelerômetro e  
inteligência computacional

Dissertação apresentada à Escola  
Politécnica da Universidade de  
São Paulo para obtenção do título de  
Mestre em Engenharia

São Paulo  
2013

FERNANDO GINEZ DA SILVA

Reconhecimento de movimentos humanos utilizando um acelerômetro e  
inteligência computacional

Dissertação apresentada à Escola  
Politécnica da Universidade de  
São Paulo para obtenção do título de  
Mestre em Engenharia

Área de concentração:  
Microeletrônica

Orientadora:  
Prof<sup>a</sup>. Dr<sup>a</sup>. Elisabete Galeazzo

São Paulo  
2013

## **FICHA CATALOGRÁFICA**

**Silva, Fernando Ginez da**

**Reconhecimento de movimentos humanos utilizando um acelerômetro e inteligência computacional / F.G. da Silva. -- São Paulo, 2013.**

**90 p.**

**Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Sistemas Eletrônicos.**

**1.Acelerômetro 2.Reconhecimento de padrões 3.Processamento digital de sinais I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Sistemas Eletrônicos II.t.**

A Deus.  
Aos meus pais e meu irmão.  
À minha amada noiva Jessica.

## **Agradecimentos**

A Deus, que me deu sabedoria e coragem para superar todos os desafios decorrentes das minhas escolhas.

Aos meus pais Antonio e Elaine, meu irmão Guilherme, minha noiva Jessica e meus amigos, por compreenderem minha ausência durante todo o tempo dedicado ao desenvolvimento deste trabalho.

À professora Elisabete Galeazzo pela oportunidade, orientação, paciência e confiança em mim depositada desde o início dos meus trabalhos na pós-graduação.

Aos professores Dr. Francisco Javier Ramirez Fernandez, Maurício Oscar Perez Lisboa, Henrique Estanislau Maldonado Peres, Antonio Sandro Verri e Michel Oliveira da Silva Dantas pelas inúmeras contribuições e apoio.

Ao Ricardo Quedas de Assis, ao Leilton Scandelari Lemos e ao João Paulo de Oliveira pelo apoio, compreensão e dispensas do trabalho para o curso das disciplinas e apresentações na EPUSP como também na conferência IWASI em Bari, Itália.

Aos colegas da EPUSP, em especial ao Gerson Faria, pelas parcerias nas disciplinas cursadas e pelas contribuições ao meu trabalho.

## Resumo

Observa-se nos tempos atuais um crescente interesse e demanda por novas tecnologias de sensoriamento e interação. A monitoração, com o objetivo de reconhecimento de movimentos humanos, permite oferecer serviços personalizados em diferentes áreas, dentre elas a área de cuidados médicos. Essa monitoração pode ser realizada por meio de diferentes técnicas como o uso de câmeras de vídeo, instrumentação do ambiente onde o indivíduo habita, ou pelo uso de dispositivos pessoais acoplados ao corpo. Os dispositivos acoplados ao corpo apresentam vantagens como baixo custo, uso confortável, além de muitas vezes serem despercebidos pelo usuário, diminuindo a sensação de invasão de privacidade durante a monitoração. Além disso, o dispositivo sensor pode ser facilmente acoplado ao corpo pelo próprio usuário, tornando o seu uso efetivo.

Deste modo, este trabalho apresenta o desenvolvimento de um sistema que emprega técnicas de inteligência computacional e um acelerômetro facilmente acoplado ao punho do usuário para efetuar, de maneira confortável e não invasiva, o reconhecimento de movimentos básicos da rotina de uma pessoa. Aplicando máquinas de vetores de suporte para classificar os sinais e a razão discriminante de Fisher para efetuar a seleção das características mais significativas, o sistema apresentou uma taxa de sucesso em torno de 93% no reconhecimento de movimentos básicos efetuados por indivíduos monitorados.

O sistema apresenta potencialidade para ser integrado a um hardware embarcado de baixo custo, responsável pelo gerenciamento da aquisição dos dados e pelo encaminhamento das informações a um sistema de monitoramento ou armazenamento. As informações providas por este sistema podem ser destinadas à promoção da saúde e bem estar do indivíduo, bem como utilizadas em diagnósticos ou monitoramento remoto de pacientes em um ambiente de vida assistida.

Palavras chave: Acelerômetros; Classificação de movimentos; Sensor acoplado ao corpo; Inteligência computacional.

## Abstract

Nowadays it is observed a growing interest and demand for new sensing technologies and interaction. Monitoring with the objective of recognizing human movements, allows us to offer personalized services in different areas, among them healthcare. This monitoring can be performed through the use of different techniques such as the use of video cameras, living environment instrumentation, or the use of personal devices attached to the body, also known as wearable devices. These wearable devices have some advantages such as low cost, comfortable to use, and are often unnoticed by the user, reducing the feeling of privacy invasion during the monitoring. In addition, the sensing device can be easily attached to the body by the user itself, making its use effective.

Thus, this work presents the development of a system that uses computational intelligence techniques and an accelerometer which is easily attached to the user's wrist to perform, in a comfortable and non-invasive manner, the recognition of basic movements of a person's routine. By applying support vector machines to classify the signals and Fisher's discriminant ratio to select the most significant features, the system has shown a success rate of 93% in the recognition of basic movements performed by monitored individuals.

The system has the potential to be integrated into a low-cost embedded hardware, which is responsible for managing the data acquisition and routing the movement data to a remote monitoring system or storage. The information provided by the system can be designed to promote the health and wellness of the individual, as well used in diagnostics or remote patient monitoring in an ambient assisted living (AAL).

Keywords: Accelerometers; Movement classification; Wearable sensor; Computational intelligence.



## Sumário

1.	Introdução .....	1
1.1.	Motivação .....	1
1.2.	Objetivos .....	3
1.2.1.	Objetivo geral .....	3
1.2.2.	Objetivos específicos .....	3
1.3.	Organização desta dissertação .....	4
1.4.	Publicação .....	4
2.	Monitoração de movimentos humanos .....	5
2.1.	A movimentação humana e sua importância .....	5
2.2.	Monitoração e reconhecimento de movimentos humanos .....	7
2.3.	Monitoração utilizando acelerômetros .....	9
2.4.	Posicionamento do sensor .....	12
2.5.	Movimentos reconhecidos .....	13
3.	Dispositivos e ferramentas computacionais utilizados na monitoração e reconhecimento de movimentos humanos .....	15
3.1.	Dispositivos comerciais para monitoração pessoal .....	15
3.1.1.	GENEActiv .....	15
3.1.2.	Actiwatch AW64 .....	16
3.1.3.	Minimitter Actiwatch Spectrum .....	16
3.1.4.	Camntech MotionWatch 8 .....	17
3.1.5.	Actigraph GT3X+ .....	17
3.1.6.	Texas Instruments ez430-Chronos .....	18
3.2.	Técnicas para o processamento dos sinais .....	19
3.3.	Técnicas para a redução da dimensionalidade e seleção de características .....	21
3.3.1.	Mal da dimensionalidade .....	21
3.3.2.	Análise de componentes principais .....	23
3.3.3.	Razão discriminante de Fisher .....	24
3.3.4.	Outras técnicas .....	25
3.4.	Técnicas para o reconhecimento dos movimentos .....	25
3.4.1.	Limiaries e Regras .....	27
3.4.2.	Redes Neurais Artificiais .....	28
3.4.3.	Árvores de Decisão .....	30

3.4.4.	Máquinas de Vetores de Suporte.....	31
3.4.5.	Classificador Bayesiano Ingênuo .....	33
3.4.6.	K-vizinhos mais próximos .....	34
3.4.7.	Modelos Ocultos de Markov .....	35
3.5.	Técnicas para a avaliação de desempenho dos classificadores .....	36
4.	Metodologia .....	38
4.1.	A aquisição e transmissão dos sinais .....	38
4.1.1.	O sistema de aquisição .....	38
4.1.2.	Amostragem dos movimentos .....	40
4.1.3.	Servidor pessoal.....	41
4.2.	Processamento e classificação dos sinais .....	43
4.2.1.	Filtragem.....	44
4.2.2.	Segmentação dos dados.....	44
4.2.3.	Extração de características .....	45
4.2.4.	Normalização das características .....	47
4.2.5.	Redução de dimensionalidade .....	48
4.2.6.	Classificação dos sinais .....	48
4.3.	Avaliação do desempenho dos classificadores.....	51
5.	Resultados .....	53
5.1.	Montagem experimental .....	53
5.2.	Software para aquisição dos sinais .....	54
5.3.	Sinais coletados.....	55
5.4.	Desempenho utilizando um único classificador .....	60
5.5.	Desempenho utilizando dois classificadores .....	61
5.6.	Software para monitoração remota dos movimentos .....	62
6.	Conclusões.....	64
	Referências .....	66
	Apêndice A - Acelerômetros.....	71
	Princípios básicos.....	71
	Acelerômetros MEMS.....	75
	Microusinagem de superfície .....	75
	Microusinagem do substrato.....	76
	Acelerômetro piezoresistivo.....	78
	Acelerômetro piezoelétrico .....	79
	Acelerômetro capacitivo .....	80

O sensor utilizado neste trabalho .....	81
Anexo A – Artigo publicado .....	86

## Lista de figuras

Figura 1 - Representação em camadas de um sistema acoplado ao corpo.....	10
Figura 2 - GENEActiv desenvolvido por Activinsights Inc. ....	15
Figura 3 - Actiwatch AW64 desenvolvido por Minimitter Inc. ....	16
Figura 4 - Actiwatch Scepterum produzido pela Philips Electronics. ....	17
Figura 5 - MotionWatch 8 desenvolvido por Camntech Inc.....	17
Figura 6 - Actigraph GT3X. ....	18
Figura 7 - O relógio e o rádio receptor transmissor USB, compondo a plataforma ez430- Chronos. ....	18
Figura 8 - Fenômeno de pico .....	22
Figura 9 - (a) Plotagem de 50 amostras observadas por duas características ( $x_1$ e $x_2$ ); (b) Amostras projetadas no espaço das componentes principais ( $z_1$ e $z_2$ ). ....	23
Figura 10 - Classes com: (a) pequena variância intra-classe e pequena distância entre classes; (b) grande variância intra-classe e pequena distância entre classes; (c) pequena variância intra-classe e grande distância entre classes. ....	24
Figura 11 - Modelo de aprendizado supervisionado.....	26
Figura 12 - Sinal correspondente à aceleração de quatro quedas consecutivas de uma pessoa. ....	27
Figura 13 - Modelo de um neurônio <i>perceptron</i> . ....	28
Figura 14 - Rede neural artificial de arquitetura MLP. ....	29
Figura 15 - Exemplo de árvore de decisão. ....	30
Figura 16 - Conceito das SVMs: (a) Comparação entre duas possíveis soluções para o problema de classificação; (b) hiperplano ótimo para o problema de classes não-separáveis; (c) Classificador não-linear utilizando uma função de base radial como kernel. ....	32
Figura 17 - Visualização do classificador k-vizinhos mais próximos com $k=11$ . O círculo tracejado indica a distância que abrange os 11 exemplares e a estrela representa o padrão que se deseja classificar. ....	34
Figura 18 - Divisão do espaço de características em células, cada uma pertencendo a uma classe. À direita, a divisão em um espaço 2D, e à esquerda a divisão de um espaço 3D. ....	35
Figura 19 - Modelo oculto de Markov com três unidades ocultas, suas transições de estado e as emissões visíveis em vermelho. ....	36
Figura 20 - Diagrama simplificado do sistema de aquisição de dados.....	39
Figura 21 - Diagrama funcional do software para aquisição dos movimentos.....	41
Figura 22 - Sistema embarcado Raspberry Pi.....	42

Figura 23 - Diagrama de conexões do sistema embarcado utilizado como servidor pessoal.	42
Figura 24 - Diagrama de blocos do processamento e classificação dos sinais (fase de treinamento e definição da arquitetura).....	43
Figura 25 - Diagrama de blocos do processamento e classificação dos sinais (fase de operação) .....	43
Figura 26 - Diagrama da estrutura responsável pela filtragem dos sinais .....	44
Figura 27 - Segmentação dos dados em janelas de 128 amostras com 50% de sobreposição	45
Figura 28 - Estrutura do pré-classificador .....	49
Figura 29 - Arquiteturas propostas para a classificação dos sinais de movimentação.....	49
Figura 30 - Diagrama completo do sistema de reconhecimento de movimentos humanos...	52
Figura 31 - Sistema de aquisição acoplado o punho (em destaque os eixos de orientação do acelerômetro triaxial) .....	53
Figura 32 - Solução de sistema embarcado atuando como servidor pessoal .....	54
Figura 33 - Interface do software de aquisição dos sinais do acelerômetro. ....	54
Figura 34 - Quantidade de amostras coletadas por classe de movimento.....	55
Figura 35 - Amostras de aceleração referentes a 4,7 minutos de aquisição. ....	56
Figura 36 - Sinais após o processamento pelo filtro passa-alta utilizado na remoção da aceleração da gravidade. ....	56
Figura 37 - Representação das amostras para o movimento "em pé" nos domínios do tempo e frequência. ....	57
Figura 38 - Representação das amostras para o movimento "no computador" nos domínios do tempo e frequência.....	57
Figura 39 - Representação das amostras para o movimento "andando" nos domínios do tempo e frequência.....	58
Figura 40 - Representação das amostras para o movimento "correndo" nos domínios do tempo e frequência.....	59
Figura 41 - Representação das amostras para o movimento "subindo escada" nos domínios do tempo e frequência.....	59
Figura 42 - Representação das amostras para o movimento "descendo escada" nos domínios do tempo e frequência.....	60
Figura 43 - Interface do software para monitoração e reconhecimento dos movimentos.....	63
Figura 44 - Estrutura básica de um acelerômetro.....	71
Figura 45 - Acelerômetro sensível ao eixo x.....	72
Figura 46 - Circuito RLC paralelo. ....	73
Figura 47 - Princípio de um sistema massa-mola torcional. ....	74
Figura 48 - Canais abertos por corrosão: a) isotrópica; b) anisotrópica. ....	76

Figura 49 - Vistas lateral e superior de arranjos comuns para a suspensão da massa de prova em acelerômetros de substrato microusinado.....	77
Figura 50 - Acelerômetro piezoresistivo de 1-dimensão, baseado no conceito viga-massa de prova. (a) Representação gráfica do dispositivo; (b) Vista em corte.....	78
Figura 51 - Acelerômetro piezoelétrico com quatro suportes para a massa de prova.....	79
Figura 52 - Placa de circuito do relógio ez430-Chronos.....	81
Figura 53 - Massa suspensa por uma mola torcional.....	82
Figura 54 - Camadas do sensor CMA3000.....	83
Figura 55 - Capacitor diferencial formado pela massa inercial e os eletrodos fixos.....	83
Figura 56 - Acelerômetro VTI CMA300.....	84
Figura 57 - Vista lateral das camadas do acelerômetro CMA3000 .....	84

## Lista de tabelas

Tabela 1 - Lista de movimentações que o sistema reconhece.....	40
Tabela 2 - Avaliação do desempenho utilizando um único classificador.....	61
Tabela 3 - Matriz confusão para a arquitetura utilizando um único classificador.....	61
Tabela 4 - Limiares utilizados para pré-classificação.....	61
Tabela 5 - Avaliação do desempenho utilizando classificadores dedicados.....	61
Tabela 6 - Matriz confusão para o classificador com melhor desempenho.....	62
Tabela 7 - Desempenho obtido em sistemas semelhantes utilizando um único sensor.....	64
Tabela 8 - Características do sensor CMA3000.....	85

# 1. Introdução

## 1.1. Motivação

O reconhecimento de movimentos humanos é uma crescente e desafiadora área de pesquisa. A movimentação humana pode ser vista, em uma primeira análise, apenas como uma simples atividade física provocada pela contração voluntária dos músculos, porém qualquer movimentação é complexa a ponto de ter relações com fenômenos concernentes às condições de saúde ou até mesmo ao estado psicológico de um indivíduo (GODFREY et al., 2008; BONOMI, 2010).

A monitoração contínua e o reconhecimento dos movimentos possibilitam uma grande oferta de serviços personalizados em diferentes áreas como esportes, segurança, cuidados médicos, rastreamento, residências inteligentes, interfaces para jogos e etc (CHERNBUMROONG e ATKINS, 2011). Na área de esportes, por exemplo, as aplicações estão geralmente relacionadas ao cálculo de energia despendida durante o treino de um atleta, à intensidade da atividade realizada, à avaliação de desempenho ou até mesmo em apresentar ao usuário um guia de treino e exercícios através de seu computador ou *smartphone*. Na área de cuidados médicos encontram-se aplicações na detecção e aviso remoto sobre situações críticas como quedas de pessoas idosas ou pacientes em um hospital (HELMI e ALMODARRESI, 2009), na detecção de tremores e ataques em portadores de patologias (GIACOMOSSI, 2011), e na identificação do nível de cada uma das atividades físicas efetuadas no dia-a-dia do indivíduo, permitindo ao médico um diagnóstico melhor e mais eficiente, ou até mesmo como uma ferramenta de avaliação em um processo de reabilitação. Nas áreas de segurança e rastreamento são encontradas aplicações que armazenam registros sobre as atividades realizadas por um indivíduo monitorado, que efetuam autenticação biométrica através de sequências de movimentos, como também alertam o usuário sobre o esquecimento de determinada ação importante. Na área de automação e residências inteligentes podem ser desenvolvidas aplicações que detectam interações do estado do usuário com determinados ambientes, como por exemplo, apagar ou reduzir a intensidade das luzes da residência ao perceber que o indivíduo está deitado por um longo período, sugerindo que ele esteja dormindo.



No entanto a coleta contínua de informações sobre os movimentos do usuário pode ser extremamente incômoda, além de interferir na execução natural das suas atividades. Desta forma, a escolha adequada da técnica de monitoração está diretamente relacionada com o desempenho do sistema de reconhecimento de movimentos (CHERNBUMROONG e ATKINS, 2011).

Diversas técnicas podem ser utilizadas para avaliar e coletar dados sobre a movimentação do indivíduo. Estas técnicas podem ser divididas em: técnicas baseadas em vídeo, na instrumentação do ambiente e em sensores “vestíveis”.

A técnica baseada em vídeo está associada ao uso de câmeras, geralmente em ambiente especialmente preparado e controlado, que rastreiam as atividades do usuário continuamente. As desvantagens são a invasão de privacidade do indivíduo e as dificuldades relacionadas ao processamento de imagens, quando existem variações de luminosidade, mudanças no ambiente, ou múltiplas pessoas nas cenas capturadas (KHAN, 2011).

Já a técnica relacionada com a instrumentação do ambiente envolve a instalação de diversos sensores nos ambientes de monitoração, que podem ser tanto um laboratório ou até mesmo a residência do indivíduo monitorado. Exemplos de sensores utilizados para este fim são placas de pressão, chaves do tipo liga-desliga, etiquetas inteligentes, microfones, entre outros. Esta técnica tem um custo razoavelmente elevado, pois são necessários muitos sensores, e pode também enfrentar as dificuldades relacionadas à diferenciação entre o indivíduo de interesse e outros presentes no mesmo ambiente (GODFREY et al., 2008).

A técnica que abrange os denominados sensores “vestíveis” (*wearable sensors*) consiste em sistemas projetados para o uso diário e emprega a utilização de sensores capazes de obter informações fisiológicas ou mecânicas do indivíduo monitorado, dependendo dos requisitos para a aplicação desejada. Destacam-se os acelerômetros entre os sensores mais utilizados em sistemas vestíveis. Graças aos avanços na área dos MEMS (Micro-Electro-Mechanical Systems), encontram-se comercialmente acelerômetros com tamanho muito reduzido, baratos e confiáveis, viabilizando sua aplicação na monitoração não obstrutiva dos movimentos do indivíduo. Ressalta-se, porém, que a abordagem realizada por alguns sistemas baseados em sensores “vestíveis”, que se utilizam de diversos sensores acelerômetros e ou giroscópios (instados em diferentes regiões do corpo do

indivíduo para capturar sinais de movimentos distintos), pode ocasionar uma limitação na execução das atividades diárias, devendo ser levada em consideração.

Deste modo, o objetivo desta pesquisa é propor um sistema de reconhecimento automático de movimentos utilizando-se de um único sensor acelerômetro, instalado no punho do indivíduo, resultando num conforto semelhante ao uso de um relógio comum.

Uma atividade de reconhecimento de movimentos para os seres humanos pode ser muito simples, e pode ser realizada através de observação e decisão a partir de experiências previamente adquiridas (KHAN, 2011). Já no sistema de reconhecimento automático de movimentos que se propõe neste estudo, toda observação será feita através dos sinais elétricos do sensor acelerômetro, e qualquer decisão será tomada a partir da utilização de técnicas de inteligência computacional envolvendo aprendizado de máquina.

## ***1.2. Objetivos***

### **1.2.1. Objetivo geral**

Desenvolver um sistema não intrusivo, baseado em um acelerômetro instalado no punho do indivíduo e em técnicas de inteligência computacional, para reconhecer movimentos específicos da rotina de uma pessoa monitorada.

### **1.2.2. Objetivos específicos**

- Desenvolver a infraestrutura necessária para coleta e armazenamento das amostras de aceleração, obtidas com um único acelerômetro triaxial instalado no punho de um indivíduo;
- Desenvolver um sistema capaz de processar as amostras de aceleração previamente coletadas para treinar um algoritmo de reconhecimento de padrões;
- Avaliar o desempenho do reconhecimento de movimentos em função da escolha das características extraídas dos sinais de aceleração por diferentes técnicas de seleção;
- Avaliar o desempenho do reconhecimento de movimentos em função de diferentes algoritmos de reconhecimento de padrões baseados em

treinamento supervisionado como redes neurais artificiais, máquinas de vetores de suporte e k-vizinhos mais próximos;

- Desenvolver um sistema completo de reconhecimento de movimentos, empregando as ferramentas computacionais selecionadas a partir das avaliações de desempenho, disponibilizando as informações do reconhecimento para aplicações mais específicas.

### ***1.3. Organização desta dissertação***

Os próximos capítulos deste trabalho estão organizados da seguinte maneira:

- O capítulo 2 apresenta os aspectos do estudo da movimentação humana, dando enfoque nas características relacionadas à monitoração utilizando acelerômetros;
- O capítulo 3 apresenta dispositivos de hardware e ferramentas computacionais comumente empregadas na monitoração e reconhecimento de movimentos humanos;
- O capítulo 4 descreve a metodologia empregada para o desenvolvimento deste trabalho;
- O capítulo 5 apresenta os resultados obtidos;
- Por fim no capítulo 6 são apontadas as conclusões e considerações finais sobre os resultados obtidos neste trabalho.

### ***1.4. Publicação***

O conteúdo desta dissertação deu origem à publicação do artigo *Accelerometer Based Intelligent System for Human Movement Recognition*, publicado nos anais do 5th IEEE International Workshop on Advances in Sensors and Interfaces (anexado ao final deste trabalho).

## **2. Monitoração de movimentos humanos**

Neste capítulo será apresentada uma revisão da bibliografia sobre o estudo da movimentação humana e a sua monitoração. Serão também discutidos aspectos relacionados à monitoração dos movimentos por meio de acelerômetros, já que este é o foco deste trabalho, abordando aspectos do posicionamento do sensor no corpo do indivíduo e os movimentos passíveis de reconhecimento de acordo com a quantidade e posicionamento dos sensores.

### ***2.1. A movimentação humana e sua importância***

Em uma visão superficial, o conceito de movimento humano aparenta ser elementar, facilmente definido e governado por princípios simples e diretos. Essa visão induz a um entendimento limitado de que o movimento humano é apenas um caso particular de movimento em seu significado geral, sendo este definido como uma simples mudança de posição. Neste sentido, a interpretação da movimentação humana como uma simples mudança de posição do corpo ou de suas partes é incapaz de caracterizar as qualidades e elementos relacionados à movimentação (BROOKE e WHITING, 1973), e que justificam o grande interesse nesta área de pesquisa.

Na realidade, o estudo do movimento humano é uma tarefa complexa, desafiadora e objeto de pesquisas multidisciplinares, integrando o trabalho de pesquisadores de diferentes áreas tais como medicina, fisioterapia, educação física, psicologia e outras. O estudo da movimentação humana pode ser feito levando-se em conta diferentes abordagens e distinções. Uma distinção possível é feita entre movimentos inconscientes tais como tremores, tiques nervosos e reflexos, e as ações executadas intencionalmente, pressupondo uma formulação de raciocínio antes da sua execução. Outras distinções podem considerar o contexto, objetivo e a função da ação executada, levando à conclusão de que o movimento humano não é uma unidade homogênea, pois varia desde funções orgânicas básicas até o envolvimento em formas de movimento simbólico, apresentando um contexto muito amplo, que pode incluir movimentos locomotores, movimentos operacionais gerais, movimentos expressivos, movimentos atléticos, movimentos artísticos, movimentos dramáticos e movimentos ritualísticos (RENSHAW, 1973).

Nos trabalhos de (TREW e EVERETT, 2001) e (GODFREY et al., 2008) são listados alguns fatores internos e externos que afetam a movimentação humana, mostrando que cada movimentação pode ser analisada como a seguir:

- Anatomicamente: descrevendo a estrutura do corpo e a relação entre diferentes partes;
- Fisiologicamente: preocupando-se na maneira como o corpo inicia e controla o movimento;
- Mecanicamente: analisando as relações de força, tempo e distância;
- Psicologicamente: examinando as sensações, percepções e motivações que estimulam a execução de um movimento. (Os fatores emocionais e cognitivos afetam o desejo de manter produtividade, independência e interação (movimentação) no ambiente onde a pessoa vive);
- Sociologicamente: considerando os diferentes significados dados aos movimentos em diferentes contextos humanos, e a influência do contexto social sobre os movimentos executados;
- Ambientalmente: considerando a influência do ambiente no modo como os movimentos são executados. (Considera-se, por exemplo, se a habitação do indivíduo é urbana ou rural, se vive sozinho ou na companhia de outros, o tipo de trabalho que efetua, se compartilha das atividades domésticas, etc.).

Os fatores citados afetam a quantidade e a forma como movimentações e atividades são executadas. Esta relação introduz o conceito de que, a partir de dados obtidos durante a monitoração contínua dos movimentos de uma pessoa, podem-se extrair informações complexas que relacionem a execução de um movimento a um determinado contexto que o motivou efetuar-lo, ou ainda registrar os diferentes tipos de movimentos em uma base de dados para fins específicos e etc.

Tendo em vista a complexidade das relações que envolvem a movimentação humana, é fácil presumir que ela possui também grande importância para a saúde de um ser humano. Segundo (WHO, 2010), a inatividade física, ou sedentarismo, é um fator de risco responsável por 6% da mortalidade global. O envelhecimento da população, a urbanização desordenada e globalização contribuem para o aumento de hábitos e ambientes não saudáveis, aumentando o número de pessoas com doenças não contagiosas (entre elas doenças crônicas, doenças autoimunes, doenças cardíacas e câncer). Além da questão patológica, a movimentação de uma

pessoa influencia a sua vitalidade e, por consequência, a sua qualidade de vida (GODFREY et al., 2008). Portanto, a monitoração e informação ao indivíduo sobre o tipo e quantidade de movimentos realizados ao longo de um período podem ser utilizadas como fatores motivacionais para o aumento da atividade física.

## ***2.2. Monitoração e reconhecimento de movimentos humanos***

Com a rápida evolução da tecnologia presente nos computadores pessoais, nos sensores e nos dispositivos de comunicação que utilizamos no dia-a-dia, é crescente o número de pesquisas que aplicam técnicas de inteligência computacional para o reconhecimento de movimentos e atividades humanas, e dentre elas destaca-se o reconhecimento de padrões. Como discutido anteriormente, a movimentação humana envolve muitos aspectos que influenciam diretamente a saúde e o bem-estar de uma pessoa. Tendo em vista o alto custo envolvido na promoção das políticas de saúde pública, somado aos quadros já introduzidos de sedentarismo e envelhecimento da população, uma aplicação que tem recebido grande foco de pesquisas é a dos ambientes de vida assistida (do inglês, *Ambient Assisted Living* ou AAL). Nesta aplicação, uma rede de sensores é instalada no ambiente onde o usuário reside estabelecendo monitoração constante com o mínimo de invasão de privacidade, permitindo que os desvios comportamentais ou situações de emergência sejam gerenciados e analisados pelos profissionais competentes, de modo a antecipar situações de risco e encaminhar a ajuda adequada quando necessário (NEHMER et al, 2006).

Além das aplicações médicas já mencionadas, muitas pesquisas são voltadas à área de entretenimento e de interatividade digital (YANG; WANG; CHEN, 2008), devido à necessidade de diminuir a distância existente entre humanos e os sistemas computacionais presentes na vida cotidiana. Outras aplicações focam o monitoramento com o objetivo de vigilância e rastreamento. Um exemplo é apresentado por (KOSKIMÄKI et al., 2011), onde os movimentos registrados por sensores acoplados ao punho dos trabalhadores em uma linha de montagem são relacionados com as tarefas já executadas, preenchendo automaticamente um “*check-list*” e avisando sobre ações que possam ter sido esquecidas.

Como o reconhecimento de movimentos humanos é feito a partir de amostras capturadas durante um período de monitoração contínua de um indivíduo, a coleta

destes dados pode ser feita de diferentes maneiras, sendo classificadas como técnicas subjetivas ou objetivas (YANG e HSU, 2010).

As técnicas subjetivas são baseadas em diários, pesquisas e questionários, que podem ser preenchidos pelo próprio indivíduo monitorado. Essas técnicas apresentam baixíssimo custo, mas em contrapartida apresentam a subjetividade do julgamento individual durante o preenchimento, dependem da memória do indivíduo, podem apresentar a falta ou excesso de informações, levando a interpretações imprecisas ou até mesmo equivocadas.

As técnicas objetivas são baseadas em medições por meio de sensores dos mais diversos tipos. Estes sensores podem ser divididos em: sensores de movimentação, fisiológicos, de contexto e de imagem. Os atuais sistemas de reconhecimento de movimentos utilizam informações extraídas exclusivamente de um tipo de sensor ou de uma rede composta por diversos elementos, para aumentar o sucesso no reconhecimento ou mesmo para aumentar o número de diferentes movimentos reconhecidos. Cada abordagem apresenta vantagens e desvantagens, relacionadas principalmente ao custo dos sensores, facilidade de uso e da sua instalação, conforto do usuário, liberdade para execução das atividades rotineiras e possibilidade de uso fora de um ambiente controlado (por exemplo, um laboratório).

Os sensores de movimentação são dispositivos instalados diretamente sobre o corpo ou vestuário. Estes dispositivos podem ser pedômetros, chaves acopladas aos calçados, acelerômetros, giroscópios e etc. O pedômetro é o dispositivo mais simples e barato para avaliação da movimentação humana. Este dispositivo é constituído de um oscilador (geralmente uma massa acoplada a uma mola) que detecta os impactos resultantes dos passos durante uma locomoção. Essa contagem permite estimar a distância caminhada e o gasto de energia, no entanto é realizada de uma maneira imprecisa, pois este dispositivo não registra a intensidade da atividade de locomoção.

Os sensores fisiológicos incluem dispositivos de medição de frequências cardíacas, pressão sanguínea, temperatura, transpiração, troca de gases respiratórios, EMG (eletromiografia), e outros (YANG e CHO, 2008).

Já os sensores contextuais trazem informações sobre o contexto ou ambiente onde o movimento ou atividade está sendo executado(a). Estes sensores podem ser identificadores RF (RFID), sensores de infravermelho passivo, sensores de pressão

instalados sob placas no piso ou objetos (LIM et al., 2008), como também chaves instaladas em portas ou suportes de objetos.

Os sensores de imagem são utilizados para captar sequências de vídeo, realizadas por uma ou mais câmeras e focadas no indivíduo durante a execução de suas atividades. Com o uso de técnicas computacionais os padrões de movimentação são então extraídos e reconhecidos (AGGARWAL e CAI, 1999).

Já os sensores de tamanho reduzido, como são os acelerômetros, giroscópios e alguns sensores fisiológicos, aliados aos avançados sistemas computacionais portáteis existentes atualmente, permitem o desenvolvimento de sistemas acoplados ao corpo (denominados *wearable systems*). Estes sistemas correspondem a equipamentos que os usuários podem levar consigo acoplados em relógios, óculos, cintas, ou presos no tecido de suas roupas, nos bolsos e etc. Ao contrário dos equipamentos de mão, estes dispositivos funcionam sem que o usuário precise manipulá-los constantemente, e geralmente possuem uma funcionalidade bem específica (COULOURIS; DOLLIMORE; KINDBERG, 2007), que neste caso é monitorar as movimentações humanas.

Desta forma, os sistemas acoplados ao corpo oferecem grande vantagem sobre os dispositivos de vídeo e sensores que necessitam de uma infraestrutura especial, pois podem ser utilizados durante o dia-a-dia do indivíduo sem interferências.

### ***2.3. Monitoração utilizando acelerômetros***

Os acelerômetros são sensores que fornecem um sinal elétrico em tempo real da aceleração projetada sobre os eixos sensíveis, sendo muito adequados para a monitoração de movimentos humanos. Por fornecer uma informação de frequência e intensidade do movimento, os acelerômetros são superiores aos dispositivos mais simples (pedômetros e chaves), que apenas respondem aos impactos ou inclinações (GODFREY et al., 2008). Com a miniaturização e queda no custo, os acelerômetros tornaram-se dispositivos de uso muito atrativo em sistemas acoplados ao corpo, oferecendo como vantagens: coletar dados objetivamente e permitir a análise direta da movimentação; monitorar eventos adversos, como quedas e tremores; possibilitar a monitoração em longo prazo, permitindo identificar tendências e lentas mudanças comportamentais nas movimentações de uma pessoa (ERMES et al., 2009).



Informações detalhadas sobre os diferentes tipos e aspectos construtivos dos acelerômetros podem ser vistas no “Apêndice A” deste trabalho.

Para que essas vantagens sejam efetivas e o sistema de monitoração possa ser utilizado também em um ambiente doméstico e não supervisionado, o mesmo deve ser confiável e robusto, pois em grande parte do tempo será operado por não profissionais; deve ser leve e não obstrutivo, permitindo a execução das atividades normais de uma pessoa; ter uma aparência atrativa, incentivando o uso prolongado; além disso, é desejável que se comunique automaticamente com uma central de dados, ou que possua capacidade de armazenamento para pós-processamento; deve ser calibrado automaticamente, evitando muitas interações do usuário; e obviamente deve resistir às movimentações (do usuário) e ser imune a luz ambiente (PÄRKKÄ, 2011).

Os sistemas acoplados ao corpo podem integrar o sensoriamento, o condicionamento e o processamento dos sinais, mas não necessariamente em uma mesma unidade de *hardware*.

Figura 1 - Representação em camadas de um sistema acoplado ao corpo.



Fonte: Adaptado de Luprano, 2004

A Figura 1 esboça uma representação em camadas de um sistema acoplado ao corpo, onde cada camada representa uma função específica do processo de reconhecimento de movimentos. Nesta representação a camada “Vestuário e/ou Sensores” correspondente à estrutura que permite o posicionamento do sensor acelerômetro. A camada subsequente a esta, denominada “condicionamento e filtragem”, é responsável pela conversão analógico-digital dos sinais provenientes do sensor e pela sua filtragem se houver necessidade. Na sequência, a camada de pré-processamento realiza operações matemáticas sobre as amostras de movimentação, extraindo parâmetros (ou características) representativos que permitam caracterizar cada um dos sinais de interesse. A última camada, que

antecede a apresentação dos resultados a uma “aplicação”, corresponde ao “processamento” dos parâmetros extraídos na camada inferior e é feito por algoritmos de inteligência computacional (focados no reconhecimento de padrões), permitindo associar um conjunto de parâmetros extraídos das amostras do sinal de aceleração a um rótulo identificador ou a um valor previamente especificado, que represente o resultado do reconhecimento de um movimento humano.

Contudo, por razões de limitação de memória de armazenamento ou de capacidade de processamento, o sistema acima exemplificado pode ser dividido em mais de uma unidade, e pode ou não realizar o processamento dos dados coletados em tempo real. Deste modo, segundo (KHAN, 2011), os sistemas acoplados ao corpo podem ser categorizados em:

- *Sistema processador de dados*: Realiza a aquisição, o pré-processamento e a classificação dos movimentos no próprio *hardware* acoplado ao corpo. Em geral consome mais energia devido à presença de um processador de maior poder computacional, porém não necessita de grande quantidade de memória de armazenamento;
- *Sistema armazenador de dados*: Realiza a aquisição e armazena os dados brutos em uma memória não-volátil, para que o processamento seja feito futuramente em outra unidade de *hardware*. Este tipo de sistema possui a vantagem de utilizar um processador mais simples, porém necessita de uma memória suficientemente grande para armazenar quantidades significativas de dados (adquiridos em dias ou semanas). Uma desvantagem deste sistema é não ser possível aplicá-lo em situações que dependam da geração de alertas, pois os dados não são processados em tempo real;
- *Sistema transmissor de dados*: Realiza a aquisição e transmite as amostras para um computador local ou remoto, onde o processamento será realizado. A vantagem deste sistema é a redução no seu peso e no consumo de energia, além de utilizar pouca memória e um processador mais simples. Em geral sistemas como este utilizam comunicação RF, Bluetooth ou WLAN para transmissão de dados e a sua operação está sujeita ao alcance do receptor, impondo uma limitação no uso a ambientes domésticos.

## ***2.4. Posicionamento do sensor***

Visto que a monitoração contínua dos movimentos de uma pessoa deve ser feita mantendo sua liberdade e conforto para que não ocorram interferências na execução das atividades, deve-se pensar na fixação do sensor em um local do corpo onde esses requisitos sejam atingidos.

Além da questão do conforto, o posicionamento do sensor está diretamente relacionado à parte do corpo que é estudada, ou aplicação à qual se destinam as informações do monitoramento. Para a análise de tremores, por exemplo, os sensores são instalados nos punhos (GIACOMOSSI, 2011; ERMES et al., 2009; KOSKIMÄKI et al., 2011); já para o reconhecimento de muitas atividades são instalados múltiplos sensores: nas extremidades dos membros superiores e inferiores (BAO e INTILLE, 2004), como também no punho e cintura (PÄRKÄ, 2011) ou na coxa (UGULINO et al., 2012); já em abordagens mais simples utiliza-se apenas um sensor próximo ao centro do corpo ou no peito (MATHIE, 2003; YAMANA, 2007; KARANTONIS et al., 2006; BAEK et al., 2004; GODFREY et al., 2011; WANG et al., 2011).

Em geral, verifica-se que o sinal de saída do acelerômetro varia de acordo com a localização do sensor no corpo do indivíduo monitorado. Com o sensor posicionado em um membro inferior, obtêm-se sinais com intensidade e frequência mais elevadas, principalmente durante atividades que envolvam a movimentação de membros inferiores; com o sensor montado no peito, próximo ao centro de gravidade do corpo, os sinais possuem intensidade e frequência mais moderadas, porém oferecem mais facilidade na determinação de parâmetros posturais do corpo.

Os sistemas multissensoriais resultam em melhor desempenho no reconhecimento de movimentos, já que fornecem informações sobre a movimentação em diferentes partes do corpo. Por outro lado, apresentam a desvantagem da dificuldade de instalação, pois se algum dos sensores for incorretamente posicionado os dados podem ser comprometidos, além do desconforto de “carregar” vários sensores durante as atividades diárias, influenciando a maneira como elas ocorrem (CHERNBUMROONG e ATKINS, 2011).

Como já mencionado em outras seções, sistemas baseados em um único sensor representam uma melhor opção para a monitoração em um ambiente da vida real, pois mesmo fornecendo menos informações e limitando a quantidade e a

complexidade dos movimentos reconhecidos, a interferência será menor tanto na maneira como na quantidade de movimentos executados. A localização deste sensor deve também privilegiar sua fixação acoplada ao corpo, para prevenir qualquer movimentação do dispositivo em relação ao corpo do indivíduo, pois caso isso ocorra poderá alterar a orientação dos eixos referenciais e a tarefa de reconhecer as diferentes movimentações será mais desafiadora. Portanto, deve-se evitar uma utilização livre do sensor, como por exemplo, dentro de um bolso (KHAN, 2011).

## ***2.5. Movimentos reconhecidos***

Os movimentos reconhecidos pelos sistemas de monitoramento utilizando acelerômetros acoplados ao corpo têm a sua complexidade limitada pela quantidade de sensores utilizados, e principalmente pelo seu posicionamento no corpo do indivíduo.

Por esta razão, em geral o foco dos sistemas de reconhecimento de movimentos utilizando acelerômetros é identificar alguns movimentos básicos presentes na rotina das pessoas, tais como andar, correr, permanecer sentado, permanecer em pé, subir ou descer escadas, e etc.

As abordagens multissensoriais (BAO e INTILLE, 2004; ERMES et al., 2009, PÄRKÄ, 2011) permitem o reconhecimento de um número maior de movimentos, como também o reconhecimento de algumas atividades mais específicas como remar ou caminhar com bastões (ERMES et al., 2009; PÄRKÄ, 2011), caminhar carregando objetos ou subindo uma escada rolante (BAO e INTILLE, 2004). Há também situações onde somente algumas movimentações mais básicas são analisadas (UGULINO et al., 2012) como andar, levantar-se, sentar-se e deitar, e a abordagem multissensorial neste caso é adotada para aumentar a precisão do sistema de reconhecimento. Por outro lado, sistemas baseados num único acelerômetro acoplado ao punho (GIACOMOSSI, 2011; CHERNBUMROONG e ATKINS, 2011; HAAPALAINEN et al., 2009; YANG e CHO, 2008; BERSCH et al., 2011) permitem o reconhecimento de atividades motoras como esfregar, escovar os dentes, trabalhar no computador, visto que envolvem movimentações expressivas do punho de um indivíduo.

Neste trabalho será avaliado o desempenho obtido com um único sensor instalado no punho, oferecendo conforto como também praticidade de uso, e focado no reconhecimento de movimentações básicas diárias de uma pessoa.

### **3. Dispositivos e ferramentas computacionais utilizados na monitoração e reconhecimento de movimentos humanos**

Neste capítulo serão apresentados alguns exemplos de dispositivos empregados na monitoração de movimentos humanos, dando ênfase ao hardware utilizado neste trabalho, e em seguida serão apresentadas as ferramentas computacionais comumente aplicadas em cada uma das etapas do processo de reconhecimento dos movimentos utilizando inteligência computacional.

#### ***3.1. Dispositivos comerciais para monitoração pessoal***

O mercado atualmente disponibiliza algumas soluções baseadas em um dispositivo acoplado ao punho para o monitoramento de movimentos e até mesmo para o seu reconhecimento. Algumas soluções comerciais são mais simples, destinadas apenas para o registro de intensidade das atividades, outras mais elaboradas armazenam todos os dados fornecidos pelo acelerômetro para processamento futuro, como há também uma solução que permite a coleta remota dos sinais brutos de aceleração. A seguir serão apresentados alguns exemplos de dispositivos comerciais, suas principais funções e aplicações para monitoração pessoal.

##### **3.1.1. GENEActiv**

Figura 2 - GENEActiv desenvolvido por Activinsights Inc.



Fonte: ActivInsights, 2011.

O GENEActiv (ilustrado na Figura 2) possui um acelerômetro MEMS triaxial, com sensibilidade de  $\pm 8g$ , um fotodiodo para sensoriamento da luz ambiente e um termistor para medição de temperatura. O dispositivo armazena até 512 MB de dados brutos, que podem ser coletados a uma taxa de amostragem configurável

entre 10 Hz e 100 Hz. A comunicação com um equipamento externo é feita através de uma interface USB.

Suas aplicações típicas são a monitoração de atividades físicas e estilo de vida, e identificação de atividades e posturas (GENEACTIV, 2011).

### 3.1.2. Actiwatch AW64

O Actiwatch 64 (ilustrado na Figura 3) é focado no estudo de distúrbios do sono, pois realiza apenas a integração dos sinais de aceleração por um intervalo de tempo ajustável denominado época, tendo como resultado apenas a intensidade de atividade por época. Este dispositivo foi utilizado pela NASA na estação espacial internacional (ISS) durante as expedições 14, 15, 16, 17, 18, 19/20, 21/22, 23/24, 25/26, para a avaliação dos efeitos do vôo espacial sobre a quantidade de movimentação e principalmente sobre o sono dos astronautas (NASA, 2012).

Figura 3 - Actiwatch AW64 desenvolvido por Minimitter Inc.



Fonte: Mini-Mitter, 2005.

### 3.1.3. Minimitter Actiwatch Spectrum

Este dispositivo (ilustrado na Figura 4) possui um acelerômetro piezoelétrico com sensibilidade de 0,5 g a 2 g, utilizado para registrar a intensidade de atividade por época (15 s, 30 s ou 1 min.), um sensor de luminosidade e um sensor capacitivo para detectar a remoção do relógio. Os dados são enviados a um computador externo através de uma interface USB presente no relógio (PHILIPS, 2012).

Figura 4 - Actiwatch Spectrum produzido pela Philips Electronics.



Fonte: Philips, 2012.

### 3.1.4. Camntech MotionWatch 8

Este dispositivo (ilustrado na Figura 5) contém um acelerômetro MEMS triaxial, com sensibilidade de  $\pm 8$  g e taxa de amostragem configurável entre 3 Hz e 11 Hz. Possui também um sensor de luminosidade tornando-o adequado para estudos sobre o sono humano. A memória interna é de apenas 4 MB, permitindo o armazenamento de algumas épocas de amostragem.

Figura 5 - MotionWatch 8 desenvolvido por Camntech Inc.



Fonte: Camntech, 2012.

O dispositivo armazena dados sobre a quantidade de movimentos e o nível de luminosidade ao qual está sujeito, para posteriormente enviar os dados a um computador externo onde serão analisados (CAMNTECH, 2012).

### 3.1.5. Actigraph GT3X+

O dispositivo Actigraph GT3X (ilustrado na Figura 6) contém um sensor de luminosidade e um acelerômetro triaxial com sensibilidade de  $\pm 6$  g e taxa de amostragem configurável entre 30 Hz e 100 Hz. Para amostrar os movimentos executados por um indivíduo este dispositivo pode ser acoplado ao punho, cintura, coxa ou tornozelo. Os dados brutos armazenados em sua memória interna podem



ser coletados por um computador externo através de sua interface USB (ACTIGRAPH, 2012).

Figura 6 - Actigraph GT3X.



Fonte: Actigraph, 2012.

### 3.1.6. Texas Instruments ez430-Chronos

O ez430-Chronos (ilustrado na Figura 7) é uma plataforma de desenvolvimento que integra um circuito de comunicação sem fio, um sensor acelerômetro MEMS capacitivo (triaxial) configurado para a sensibilidade de  $\pm 2$  g e 33 Hz de taxa de amostragem, um sensor de temperatura e um sensor de pressão, inseridos em um relógio esportivo.

Figura 7 - O relógio e o rádio receptor transmissor USB, compondo a plataforma ez430-Chronos.



Fonte: TI, 2010.

Seu sistema é composto pelo relógio e por um rádio (receptor e transmissor) USB, que permite a comunicação constante com um computador externo. Ambos dispositivos são baseados em microcontroladores de 16 bits (CC430F6137) da linha MSP430, que internamente contem um chip de RF que opera em bandas de frequência sub-1 GHz (433 MHz, neste sistema) (TI, 2010).

Por ser uma plataforma de desenvolvimento, o ez430-Chronos permite a sua completa reprogramação, além disso, suas documentações de hardware e software são disponibilizadas pelo fabricante.

As aplicações deste produto estão focadas no esporte e acompanhamento de dados pessoais. Pelas suas características técnicas, foi selecionado e será aplicado neste trabalho na coleta e reconhecimento de movimentos humanos.

### ***3.2. Técnicas para o processamento dos sinais***

Em sistemas acoplados ao corpo para identificação dos movimentos, o acelerômetro fornece um sinal elétrico contínuo de saída que é coletado por um circuito de conversão analógico-digital (A/D), geralmente contido em um circuito integrado microprocessador ou microcontrolador. Após a conversão A/D, o sinal passa a ser representado por uma sequência discreta de amostras cujo tamanho é proporcional ao tempo de amostragem.

Para executar as operações de processamento do sinal durante a utilização do dispositivo, necessita-se que essa sequência seja segmentada em trechos finitos, cujos tamanhos devem ser coerentes à aplicação onde o sensor é utilizado. No caso das movimentações humanas, o tamanho destes segmentos corresponde a alguns segundos: 1s (YAMANA, 2011; GIACOMOSSI, 2011; UGULINO et al., 2012), 2s (KOSKIMÄKI et al., 2011), 3s (KHAN, 2011), 4s (ERMES et al., 2009; PÄRKÄ, 2011) são alguns exemplos de intervalos utilizados, porém podem ter uma duração variável já que o intervalo ótimo pode ser diferente para cada tipo de movimento (MATHIE, 2003).

Os dados brutos extraídos de cada segmento, ou janela de amostras, serão processados por algum algoritmo de reconhecimento de padrões, atribuindo a este segmento um rótulo que indique a atividade contida nas amostras de aceleração coletadas. Porém os dados brutos não serão submetidos diretamente ao algoritmo, mas sim apenas alguns parâmetros (ou características) extraídos dos sinais em questão.

As vantagens de utilizar parâmetros ou características extraídas dos sinais são a redução da dimensionalidade da entrada fornecida ao algoritmo de classificação, reduzindo o “custo” computacional; além de representarem medidas com maior similaridade entre dados pertencentes a uma mesma classe, ou, em outras palavras, permitem que as amostras sejam mais facilmente separadas.

As características extraídas dos dados brutos podem ser calculadas no domínio do tempo, da frequência e tempo-frequência, como detalhadas a seguir:

**Características no domínio do tempo:** operações matemáticas são aplicadas sobre as componentes discretas no domínio do tempo, ou seja, diretamente sobre a janela. Alguns exemplos são:

- Correlação entre eixos (KHAN, 2011; CHERNBUMROONG e ATKINS, 2011; BAO e INTILLE, 2004; YANG; WANG; CHEN, 2008; LESTER; CHOUDHURY; BORRIELLO, 2006; KOSKIMÄKI et al., 2011; UGULINO et al., 2012);
- Ângulo de inclinação (KHAN, 2011; MATHIE, 2003; YAMANA, 2011; KARANTONIS et al., 2006)
- Obliquidade e curtose (ERMES et al., 2009);
- Percentil (HAAPALAINEN et al., 2009; LESTER; CHOUDHURY; BORRIELLO, 2006; KOSKIMÄKI et al., 2011);
- Área da magnitude do sinal (KHAN, 2011; MATHIE, 2003; KARANTONIS et al., 2006);
- Média, variância, mediana ou desvio padrão (ERMES et al., 2009; PÄRKÄ, 2011; GIACOMOSSI, 2011; BAO e INTILLE, 2004; HAAPALAINEN et al., 2009; YANG; WANG; CHEN, 2008; LESTER; CHOUDHURY; BORRIELLO, 2006; KOSKIMÄKI et al., 2011; UGULINO et al., 2012);
- Máximos e mínimos (GIACOMOSSI, 2011; KOSKIMÄKI et al., 2011);
- Integração da aceleração (PÄRKÄ, 2011; LESTER; CHOUDHURY; BORRIELLO, 2006);

**Características no domínio da frequência:** operações são aplicadas sobre as componentes discretas do espectro de frequência, que são obtidas após uma transformada discreta de Fourier do sinal janelado, utilizando o algoritmo da transformada rápida de Fourier (em inglês, FFT: Fast Fourier Transform). Exemplos de operações citadas são:

- Entropia espectral (PÄRKÄ, 2011; BAO e INTILLE, 2004; LESTER; CHOUDHURY; BORRIELLO, 2006);
- Centróide espectral (ERMES et al., 2009);
- Dispersão espectral (ERMES et al., 2009);
- Frequência de pico (ERMES et al., 2009; PÄRKÄ, 2011; GIACOMOSSI, 2011; LESTER; CHOUDHURY; BORRIELLO, 2006; BERSCH et al., 2011);

- Potência na frequência de pico (PÄRKÄ, 2011);
- Energia do sinal (BAO e INTILLE, 2004; LESTER; CHOUDHURY; BORRIELLO, 2006);
- Energia em algumas bandas de frequência (ERMES et al., 2009; BAO e INTILLE, 2004; LESTER; CHOUDHURY; BORRIELLO, 2006);

**Características tempo-frequência:** são obtidas por uma análise tempo-frequência, através da transformada Wavelet. Essa análise permite associar o conteúdo espectral a cada instante de tempo da janela de amostras (GODFREY et al., 2011; PREECE et al., 2009).

Em geral são extraídas características de diferentes tipos, tanto no tempo quanto na frequência, formando um vetor de características que serão utilizadas no processo de reconhecimento dos movimentos. A limitação na quantidade e complexidade das características está na disponibilidade de recursos computacionais para os cálculos e no tempo disponível para o reconhecimento de um movimento.

### ***3.3. Técnicas para a redução da dimensionalidade e seleção de características***

Após o processamento do sinal pela extração de características, os sinais de aceleração estão representados por um conjunto  $n$  dimensional de características (onde  $n$  denota o número de características), sobre as quais será aplicado o algoritmo responsável pelo reconhecimento de algum tipo de padrão, ou uma abstração de propriedades que são relevantes ao propósito de reconhecimento do problema em questão, que neste caso é o reconhecimento dos movimentos realizados pelo indivíduo.

Nos problemas de reconhecimento de padrões, o tamanho do número  $n$  tem influência direta no número de amostras (ou observações), que devem ser utilizadas para o treinamento do classificador, para que se obtenha boa capacidade de generalização (ZHENG e XUE, 2009).


#### **3.3.1. Mal da dimensionalidade**

A escolha inadequada do número de características leva ao problema denominado “mal da dimensionalidade”. Como mencionado anteriormente, o

desempenho do classificador depende da relação existente entre a complexidade do próprio classificador, do tamanho das amostras (dado pelas  $n$  características extraídas) e da quantidade de amostras disponibilizadas para o treinamento. A dificuldade de aprendizado, que resulta na baixa capacidade de generalização, é acentuada quando poucas amostras são disponibilizadas para treinamento, ou quando a dimensão  $n$  é muito elevada, o que corresponde a relações muito complexas que devem ser absorvidas pelo classificador.

O mal da dimensionalidade leva a um comportamento chamado “fenômeno de pico”, que corresponde a uma degradação do desempenho de classificação caso o número de amostras seja pequeno em relação ao número de características, como também é o caso quando o número de características é muito elevado.

Figura 8 - Fenômeno de pico



Fonte: Theodoridis e Koutroumbas, 2009

A Figura 8 ilustra o fenômeno de pico. Para um dado número  $N$  de amostras de treinamento, a probabilidade de erro de classificação  $P_e$  diminui com o aumento do número de características (aqui denotado por  $l$ ) até um ponto crítico, e após este ponto a  $P_e$  volta a subir, pois a complexidade do conjunto amostral se tornou muito elevada. Também é possível visualizar que o aumento do número de amostras de treinamento ( $N_2 \gg N_1$ ) implica no deslocamento do ponto crítico para um valor maior ( $l_2 \gg l_1$ ).

A observação deste fenômeno aponta a necessidade de se ajustar a dimensão do vetor de características, de modo a reduzir a  $P_e$  durante o projeto do sistema. Isto é feito por meio de técnicas que permitem avaliar a significância de cada uma das características para o desempenho do classificador, resultando somente na escolha das características mais significativas, reduzindo a dimensão do

vetor de características para um valor próximo do ótimo. Esta etapa essencial do sistema é denominada “seleção de características”. A seguir serão apontadas algumas técnicas comumente aplicadas na execução desta tarefa.


### 3.3.2. Análise de componentes principais

A análise de componentes principais (em inglês, PCA, *Principal Component Analysis*) é uma técnica multivariada que consiste em uma transformação linear do conjunto de dados, de modo tal que os dados transformados são projetados em um espaço que maximiza sua variância (processo ilustrado na Figura 9). Isto é, as componentes mais relevantes para a representação dos dados estão nas primeiras dimensões, denominadas componentes principais.

Detalhando algebricamente, essa transformação é baseada na matriz de covariância dos dados  $\mathbf{X}$  (matriz  $n \times p$ ), representada por  $\Sigma$ , sobre a qual são calculados os seus autovalores ( $\lambda_i | i=1, \dots, p$ ) e autovetores ( $\mathbf{v}_i | i=1, \dots, p$ ), com elementos  $v_{i1}, \dots, v_{ip}$ . Assim, os pares  $(\lambda_1, v_1), (\lambda_2, v_2), \dots, (\lambda_p, v_p)$  correspondentes aos autovalores e autovetores de  $\Sigma$  são arranjados de forma tal que  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ , formando a matriz  $\mathbf{A}$ . Com isso é possível escrever a equação (3.1), onde  $\mathbf{z}$  corresponde ao vetor de dados projetado no espaço determinado pela PCA.

$$\mathbf{z} = \mathbf{A}'\mathbf{X} \quad (3.1)$$

Figura 9 - (a) Plotagem de 50 amostras observadas por duas características ( $x_1$  e  $x_2$ ); (b) Amostras projetadas no espaço das componentes principais ( $z_1$  e  $z_2$ ).



Fonte: Jolliffe, 2002

Do ponto de vista de um problema de reconhecimento de padrões, o valor prático da PCA está na redução do número de características, e isso é realizado por

meio da eliminação das componentes principais relacionadas aos autovalores de valor mais baixo, indicando baixa variância. Os critérios utilizados na determinação do número de componentes que serão eliminadas são descritos a seguir:

- Manter um percentual mínimo da variância total do conjunto de dados, por exemplo, 80% do total, sendo que o percentual de cada componente é dado pela equação (3.2).

$$P(CP_k) = \frac{\lambda_k}{\sum_{i=1}^p \lambda_i} \quad (3.2)$$

- Eliminar as componentes principais com autovalor inferior à média dos autovalores, que é dada pela equação (3.3).


$$M = \sum_{i=1}^p \frac{\lambda_i}{p} \quad (3.3)$$

Algumas técnicas para a redução de dimensionalidade utilizando PCA são apontadas por (JOLLIFFE, 1972), e estas se baseiam na remoção das variáveis associadas aos últimos  $q$  componentes principais, ou das associadas aos primeiros  $q$  componentes principais.

### 3.3.3. Razão discriminante de Fisher

As características podem ser avaliadas por meio de medidas de separabilidade, que permitem determinar o espalhamento das amostras dentro os dados que pertencem a uma mesma classe (variância intra-classe) e o espalhamento entre dados agrupados de diferentes classes (distância entre classes). Diferentes espalhamentos são ilustrados na Figura 10.

Figura 10 - Classes com: (a) pequena variância intra-classe e pequena distância entre classes; (b) grande variância intra-classe e pequena distância entre classes; (c) pequena variância intra-classe e grande distância entre classes.



Fonte: Theodoridis e Koutroumbas, 2009.

Neste contexto, uma característica pode ser analisada de modo a se verificar a sua capacidade discriminatória, buscando uma baixa variância intra-classe e uma grande distância extra classe. Essa capacidade discriminatória é calculada por meio da denominada Razão Discriminante de Fisher (FDR, *Fisher's discriminant ratio*), cujo equacionamento é visto na equação (3.4), onde  $M$  indica o número de classes e os índices  $i$  e  $j$  são utilizados para indicar classes como  $\omega_i$  e  $\omega_j$  (THEODORIDIS e KOUTROUMBAS, 2009).

$$FDR = \sum_i^M \sum_{j \neq i}^M \frac{(\mu_i - \mu_j)^2}{\sigma_i^2 + \sigma_j^2} \quad (3.4)$$

Deste modo são elencadas apenas as características com o maior valor, indicando-as como as mais importantes para a classificação.

### 3.3.4. Outras técnicas

Sabendo-se que a busca exaustiva pelo melhor conjunto de características através da avaliação de todas as possibilidades é inviável (devido ao número de cálculos necessários), algumas realizações práticas podem ser efetuadas.

Essas realizações correspondem ao uso de algoritmos de busca ótimo (*branch and bound*), onde todos os possíveis conjuntos são avaliados sem a busca exaustiva; ou sub-ótimos, onde, a partir de uma abordagem “bottom-up” (novos atributos são adicionados) ou “top-down” (atributos são removidos do total), os conjuntos são avaliados até se atingir um critério de parada, como por exemplo, a minimização da probabilidade de erro. Esses algoritmos são abordados e detalhados em (KOHN, 1998).

## 3.4. Técnicas para o reconhecimento dos movimentos

Após a extração das características selecionadas da janela de amostras, deve-se submeter este conjunto de dados a um mecanismo de reconhecimento, para determinar o movimento contido nos sinais de aceleração.

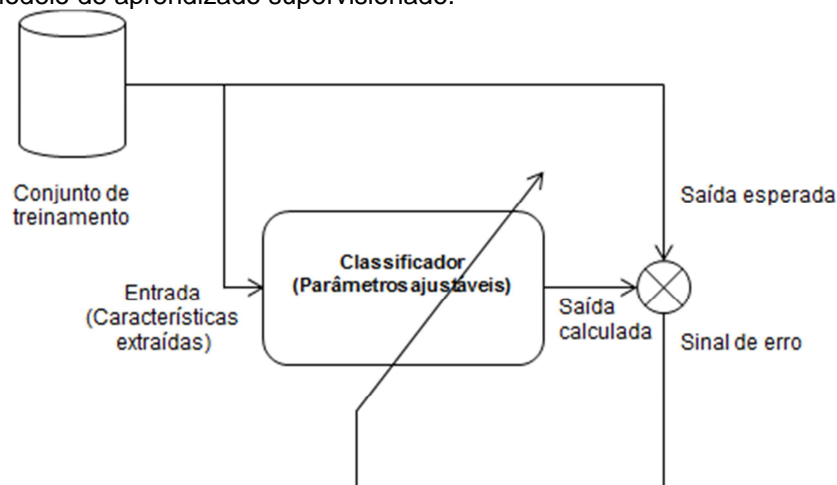
Os algoritmos comumente utilizados para este fim estão listados a seguir:

- Limiares e Regras de conhecimento a priori (YAMANA, 2011; KARANTONIS et al., 2006; MATHIE, 2003; LESTER; CHOUDHURY; BORRIELLO, 2006; BERSCH et al., 2011);



- Redes Neurais Artificiais (KHAN, 2011; GYLLENSTEN, 2010; MATHIE, 2003; ERMES et al., 2009; PÄRKA, 2011; GIACOMOSSI, 2011; CHERNBUMROONG e ATKINS, 2011; YANG; WANG; CHEN, 2008; BAEK et al., 2004);
- Árvores de Decisão (MATHIE, 2003; GYLLENSTEN, 2010; ERMES et al., 2009; PÄRKA, 2011; CHERNBUMROONG e ATKINS, 2011; BAO e INTILLE, 2004; HAAPALAINEN et al., 2008; BAEK et al., 2004; UGULINO et al., 2012);
- Máquinas de Vetores de Suporte (GYLLENSTEN, 2010);
- Classificador Bayes Ingênuo (BAO e INTILLE, 2004)
- K-vizinhos mais próximos (PÄRKA, 2011; KOSKIMÄKI et al., 2011);
- Modelos Ccultos de Markov (WANG et al., 2011; LESTER; CHOUDHURY; BORRIELLO, 2006);

Figura 11 - Modelo de aprendizado supervisionado.



Fonte: Adaptada de Haykin, 2001.


Estes algoritmos podem ser baseados no conhecimento especialista, estabelecendo regras estabelecidas por meio da experiência e estudo dos sinais coletados pelos sensores, ou baseados em técnicas estatísticas. Os algoritmos com fundamentação estatística dependem de uma etapa de ajuste, chamada treinamento, quando os parâmetros internos são modificados para que o modelo convirja para os resultados desejados.

Descrições sucintas dos principais algoritmos aplicados para reconhecimento dos movimentos serão apresentadas nas seções a seguir. O método de treinamento para estes algoritmos é chamado “treinamento supervisionado” (Figura 11), pois o

ajuste dos modelos depende da apresentação do conhecimento especialista no formato de uma base de dados contendo exemplos entrada-saída esperados (conjunto de treinamento). Aplicando um vetor de entrada do conjunto de treinamento, calcula-se um sinal de erro entre a saída desejada e a saída fornecida, e desta forma o modelo é ajustado iterativamente.

### 3.4.1. Limiares e Regras

Figura 12 - Sinal correspondente à aceleração de quatro quedas consecutivas de uma pessoa.



Fonte: Mathie, 2003.

Os algoritmos baseados em limiares e regras partem de um conhecimento especialista adquirido previamente pelo desenvolvedor através de experimentos ou pela consulta de um profissional da área em questão. Estes algoritmos geralmente correspondem a uma lista de regras do tipo “SE-ENTÃO”, avaliando os valores das características fornecidas.

A vantagem deste tipo de análise é o menor custo computacional, permitindo a sua utilização em dispositivos portáteis e em tempo real.

Os limiares são comumente utilizados na detecção de quedas de um indivíduo, emitindo um alerta caso uma variação súbita de aceleração ocorra e supere um limiar previamente estabelecido. Um exemplo dessa aplicação é visto no trabalho de (MATHIE, 2003), onde um aviso será enviado caso a aceleração supere

o limiar (indicado pela linha tracejada na Figura 12) indicativo de uma possível queda.


### 3.4.2. Redes Neurais Artificiais

As redes neurais artificiais correspondem a uma estrutura bio-inspirada, composta por grafos e diversas unidades de processamento chamadas neurônios.

Os neurônios são a unidades fundamentais de processamento e são formados por três elementos principais (HAYKIN, 2001):

- Os *elos de conexão* (sinapses), cada qual caracterizado por um peso próprio (força de conexão), ou seja, o valor aplicado ao nó de entrada será multiplicado pelo peso sináptico antes de chegar à soma do neurônio;
- A *soma*, responsável pela combinação linear de todas as entradas;
- A *função de ativação*, responsável por limitar a saída do neurônio a um valor finito e normalizado (exemplos:  $[0,1]$  ou  $[-1,1]$ ). As funções de ativação comumente utilizadas são a função limiar, a função linear por partes e a função sigmóide.

Figura 13 - Modelo de um neurônio *perceptron*.



Fonte: Haykin, 2001.

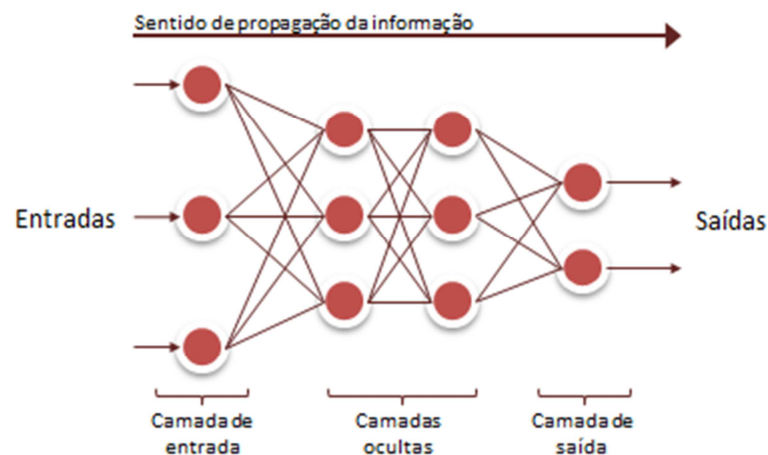
Há ainda o elemento denominado "*bias*", correspondente a uma entrada fixa que aumenta ou diminui a entrada líquida da função de ativação.

A Figura 13 apresenta o modelo de um único neurônio do tipo "perceptron", que matematicamente pode descrito pela equação (3.5).

$$y_k = \varphi \left( \sum_{i=0}^m x_i w_{ki} + b_k \right) \quad (3.5)$$

Um único “perceptron” oferece uma função de separação muito simples, mas quando várias unidades são organizadas em uma arquitetura planejada, padrões mais complexos podem ser absorvidos dos dados de entrada, transformando a rede em um aproximador universal de funções. Na arquitetura MLP (Perceptron de Múltiplas Camadas, em inglês *Multi-Layer Perceptron*), as conexões são dispostas em camadas (como ilustrado na Figura 14), e o fluxo do sinal ocorre em um sentido único, ou seja, sem realimentação.

Figura 14 - Rede neural artificial de arquitetura MLP.



Fonte: Autoria própria.

A primeira camada, contendo os nós de entrada, recebe as características extraídas no pré-processamento e a camada de saída apresenta o resultado da classificação. Entre essas duas camadas se localizam as camadas ocultas, responsáveis pelo grau de complexidade da função aproximada pela rede neural.

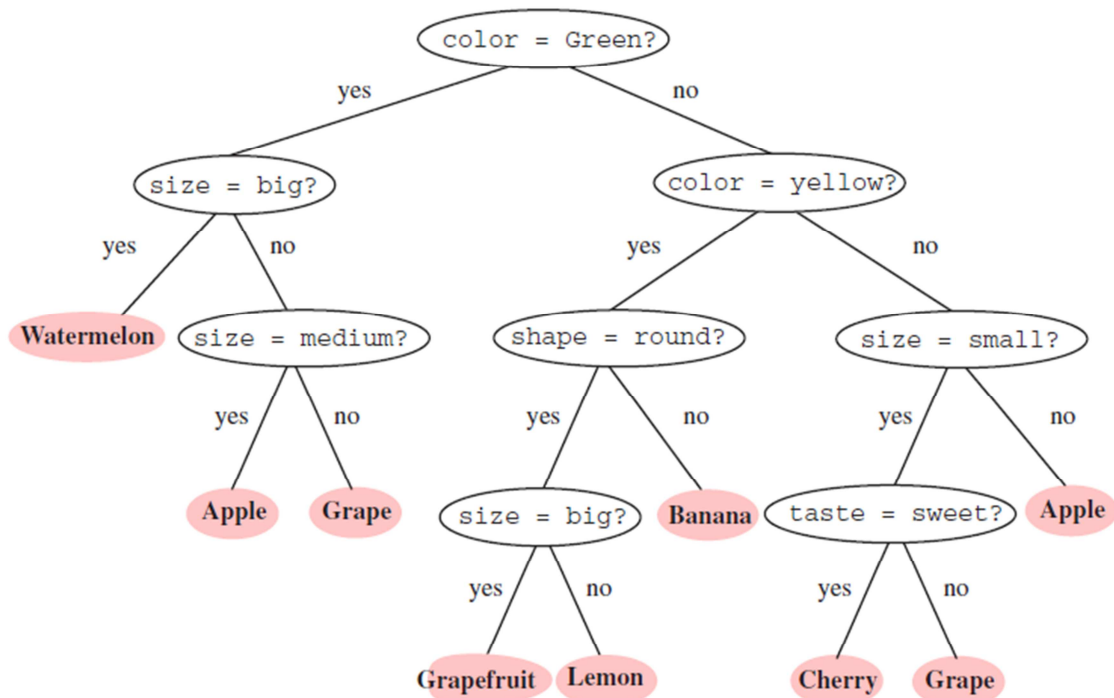
O treinamento da rede neural artificial efetua o ajuste dos parâmetros livres, pesos sinápticos e viés (“*bias*”) de cada neurônio, para que a função desconhecida, da qual se tem apenas o mapeamento entrada-saída dado pelo conjunto de dados de treinamento, seja aproximada pela rede. O algoritmo utilizado para o treinamento de uma rede neural de topologia MLP é o “Error back propagation”, que como o nome sugere, propaga o sinal de erro de forma reversa ao fluxo normal da rede, ou seja, o erro calculado entre a saída esperada e a apresentada em cada neurônio de saída é propagado para a camada anterior, e assim sucessivamente até a camada de entrada. Na propagação do erro, os parâmetros dos neurônios da camada

corrente são individualmente atualizados por um valor proporcional ao sinal de entrada e ao gradiente local, sendo este último correspondente ao gradiente descendente do erro em função dos pesos. Este processo iterativo é repetido até que o erro seja minimizado. Um detalhamento maior sobre as redes neurais MLP e algoritmos de treinamento pode ser visto em (HAYKIN, 2001).

### 3.4.3. Árvores de Decisão

As árvores de decisão correspondem a uma ferramenta de simples entendimento e capaz de receber conhecimento especialista. No exemplo ilustrado na Figura 15, a representação gráfica de uma árvore de decisão apresenta a informação de entrada na região superior da estrutura: uma amostra, ou um vetor de características; e na parte inferior são indicadas as possíveis classificações, ou seja, o resultado do algoritmo. De maneira muito semelhante ao raciocínio humano, um parâmetro é analisado a partir do nó pai, e leva a um dos caminhos bifurcados, e assim sucessivamente, até chegar ao rótulo de classificação.

Figura 15 - Exemplo de árvore de decisão.



Fonte: Duda; Hart; Stork, 2000.

O treinamento de uma árvore de decisão é feito de maneira interativa e busca maximizar a separação dos dados a cada nó de divisão. O desafio do treinamento é

determinar quais são os parâmetros que levam à otimização dessas divisões e quantas divisões são necessárias. O treinamento é interrompido quando um conjunto de dados está completamente separado, ou caso o número máximo de camadas ou divisões (previamente estabelecido pelo desenvolvedor) seja atingido. Alguns algoritmos populares para a implementação das árvores de decisão são o CART (*Classification and regression tree*), o ID3 e o C4.5 (DUDA; HART; STORK, 2000).

#### 3.4.4. Máquinas de Vetores de Suporte

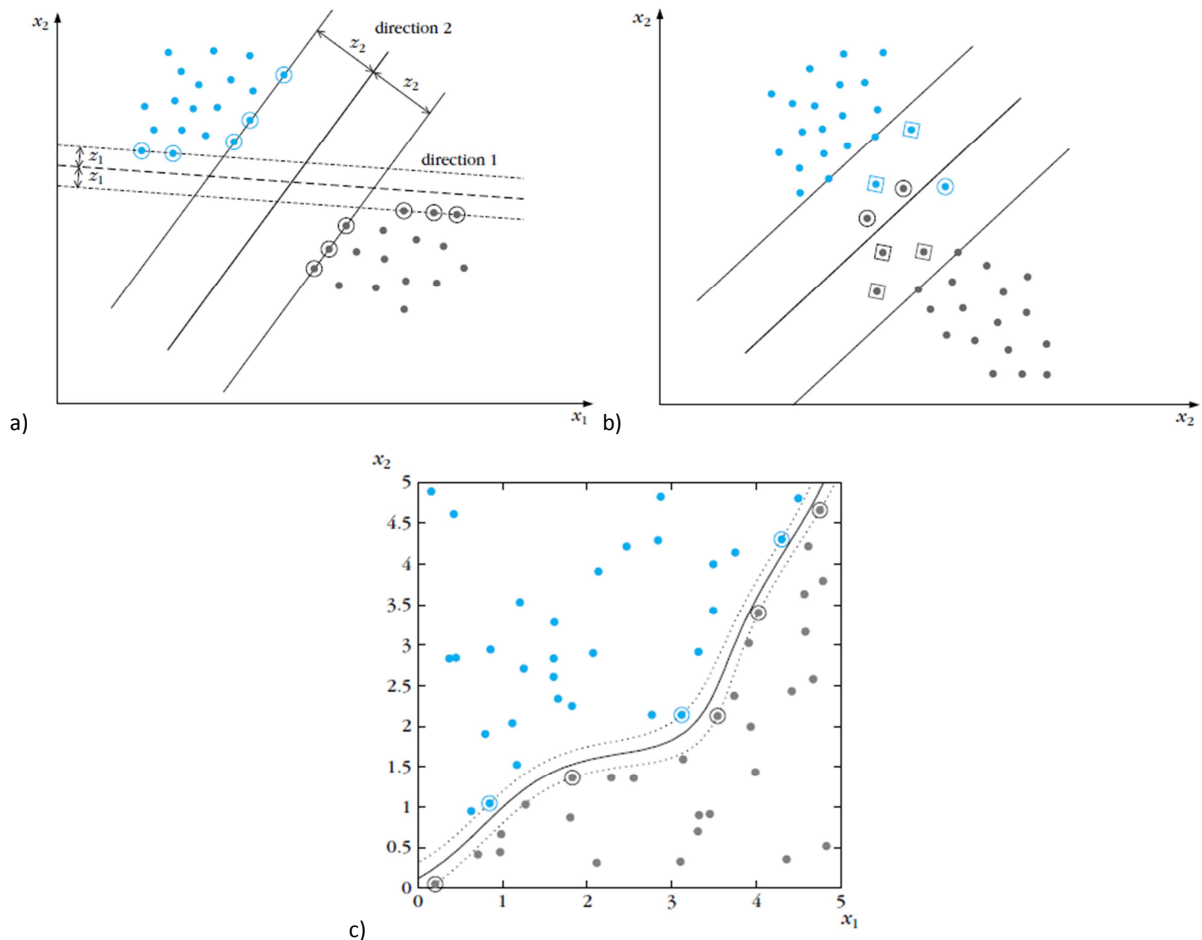
A técnica utilizada nas Máquinas de Vetores de Suporte (em inglês, SVM ou “*Support Vector Machines*”) visa encontrar o hiperplano que separa dados de duas classes distintas com a maior margem possível, sendo essa margem a distância entre um exemplar de treinamento e o hiperplano de separação. A busca pelo hiperplano ótimo é motivada pelo fato de que quanto maior a margem, melhor a capacidade de generalização do classificador (DUDA; HART; STORK, 2001). A Figura 16 apresenta dois planos, em diferentes direções, capazes de separar os dados de duas classes, onde facilmente se nota que o plano na direção 2 realiza a separação dos exemplares de treinamento com uma margem maior e, conseqüentemente, oferece melhor generalização para novos dados.

O exemplo apresentado na Figura 16a (contendo dados perfeitamente separáveis) tem caráter didático e seu principal objetivo é ilustrar o conceito principal das SVMs. Um exemplo mais adequado à realidade dos problemas de classificação é visto na Figura 16b, onde o hiperplano ótimo é encontrado levando em conta um parâmetro (ajustável pelo desenvolvedor) denominado “C”, que estabelece um custo associado aos erros de classificação.

Quando há relações mais complexas entre as características extraídas dos sinais, o classificador linear não será capaz de realizar uma boa separação das classes, porém é possível realizar um mapeamento do espaço de entrada (formado pelas características) para um espaço k-dimensional onde as classes podem ser satisfatoriamente separadas por um hiperplano como exemplificado na Figura 16c. Neste caso, a função  $\Phi$  que realiza o mapeamento, denominada função de *kernel*, pode ser do tipo polinomial, tangente hiperbólica ou de base radial (THEODORIDIS e KOUTROUMBAS, 2009).

Portanto o treinamento de uma máquina de vetores de suporte corresponde à tarefa de encontrar o hiperplano ótimo, levando-se em consideração o parâmetro de custo “C” e os parâmetros relacionados à função de *kernel* escolhidos pelo projetista do classificador.

Figura 16 - Conceito das SVMs: (a) Comparação entre duas possíveis soluções para o problema de classificação; (b) hiperplano ótimo para o problema de classes não-separáveis; (c) Classificador não-linear utilizando uma função de base radial como kernel.



Fonte: Theodoridis e Koutroumbas, 2009.

Ressalta-se que a discussão apresentada até aqui envolve problemas de classificação de apenas duas classes. Para um problema de  $M$ -classes, como é o caso de um sistema de reconhecimento de movimentos, a solução comumente adotada é a de conjuntos de classificadores de duas classes utilizando duas técnicas denominadas “um contra todos” e “um contra um”.

Na técnica “um contra todos”,  $M$  classificadores são treinados para que o hiperplano separe a classe  $\omega_i$  de todas as demais, e deste modo a classificação é dada pelo classificador que oferecer a maior resposta positiva.

Na técnica “um contra um”,  $M(M-1)/2$  classificadores são treinados para que cada par de classes seja separado, e o resultado final da classificação corresponde à classe estimada pela maioria dos classificadores.

Um exemplo da aplicação das máquinas de vetores de suporte no reconhecimento de movimentos humanos é visto no trabalho de (GYLLENSTEN, 2010), onde o sistema classificador utiliza a técnica “um contra todos” e funções de base radial como *kernel* para o mapeamento do espaço de entrada.

Maiores detalhes sobre a teoria contida nas SVMs pode ser vista em (CORTES e VAPNIK, 1995).

### 3.4.5. Classificador Bayesiano Ingênuo

O classificador bayesiano ingênuo (em inglês, “*Naive Bayes*”) baseia-se na teoria Bayesiana, que torna possível estimar diretamente a probabilidade de um dado ou padrão, descrito por um conjunto  $x$  de características, pertencer a uma classe  $\omega$  conhecida.

O teorema de Bayes, descrito na equação (3.6), apresenta os elementos necessários para o cálculo dessa probabilidade ( $P(\omega_j | x)$ ), onde  $P(\omega_j)$  representa a denominada probabilidade a priori da hipótese,  $p(x)$  a da evidência e  $p(x | \omega_j)$  a verossimilhança (que relaciona causa e efeito).

$$P(\omega_j | x) = \frac{p(x | \omega_j)P(\omega_j)}{p(x)} \quad (3.6)$$

A classificação é dada pela maior probabilidade calculada entre as classes para as características presentes em  $x$ , como mostra a equação (3.7).

$$\omega = \arg \max_{\omega_j} P(\omega_j | x) \quad (3.7)$$

Como a verossimilhança  $p(x | \omega_j)$  pode ser de difícil estimação, uma drástica simplificação é efetuada assumindo que as características são variáveis independentes, dando origem ao termo “ingênuo” presente no nome deste classificador. Esta técnica é especialmente apropriada quando a dimensão do espaço de características é muito elevada, tornando a estimação das densidades de probabilidade complexa. A simplificação assumida permite que distribuições unidimensionais sejam utilizadas para estimar a densidade de probabilidade de uma




característica; ou no caso de uma característica de valor discreto, um histograma pode ser utilizado de maneira transparente para determinar a densidade.

Apesar dessas suposições otimistas, os classificadores bayesianos ingênuos oferecem bom desempenho e podem até mesmo superar alternativas mais sofisticadas (HASTIE; TIBSHIRANI; FRIEDMAN, 2001).

### 3.4.6. K-vizinhos mais próximos

A classificação pela técnica de k-vizinhos mais próximos se utiliza de uma medida de proximidade entre o padrão que se deseja classificar e os padrões fornecidos durante o treinamento. Isto é, dado um padrão desconhecido e descrito pelas características presentes em um vetor  $x$ , o algoritmo irá primeiramente identificar, dentre os vetores de treinamento, os k elementos mais próximos no espaço independentemente de sua classe (Figura 17). Em seguida o algoritmo identifica dentre os k elementos quantos pertencem a cada uma das classes conhecidas, e classificará o padrão fornecido na entrada como pertencente à classe com maior número de elementos encontrados (THEODORIDIS e KOUTROUMBAS, 2009).

Figura 17 - Visualização do classificador k-vizinhos mais próximos com k=11. O círculo tracejado indica a distância que abrange os 11 exemplares e a estrela representa o padrão que se deseja classificar.




Fonte: Theodoridis e Koutroumbas, 2009.

A quantidade “k” de elementos e o tipo de distância utilizada (euclidiana, Manhattan ou Mahalanobis) são especificados a critério do desenvolvedor do classificador.

Após o treinamento do classificador com os vetores de treinamento  $x_i, i = 0, 1, \dots, N$ , o espaço fica dividido em regiões que abrangem todos os pontos de uma mesma classe mais próximos à  $x_i$  do que a qualquer outro vetor de treinamento. Essa divisão do espaço é conhecida como mosaico de Voronoi e pode ser vista na Figura 18.

Figura 18 - Divisão do espaço de características em células, cada uma pertencendo a uma classe. À direita, a divisão em um espaço 2D, e à esquerda a divisão de um espaço 3D.



Fonte: Duda; Hart; Stork, 2000.

### 3.4.7. Modelos Ocultos de Markov


Em alguns problemas de classificação de movimentos, a probabilidade de ocorrer transição entre classes por ser maior para umas classes do que para outras. Por exemplo, é altamente improvável que um indivíduo venha a sentar-se logo após descer uma escada, porém é muito mais provável que ele esteja em pé após tal movimentação (KHAN, 2010).

Os Modelos Ocultos de Markov (em inglês, HMM ou Hidden Markov Models) são frequentemente aplicados para a solução destes problemas que possuem uma “temporalidade” inerente, isto é, que consistem de um processo que se desdobra no tempo, onde o estado no tempo “t” depende diretamente do estado no tempo “t-1” (DUDA; HART; STORK, 2000). Em outras palavras, diferentemente de outros classificadores, que se baseiam apenas em um único segmento de dados fornecido, um classificador HMM é um classificador sequencial, cuja classe estimada no momento atual é dependente da classe anterior.

Um modelo oculto de Markov (apresentado na Figura 19) corresponde a uma máquina de estados finita, constituída por estados ocultos  $\omega^T = \{\omega(1), \omega(2), \dots, \omega(T)\}$ ,

uma matriz de probabilidade de transição de estados, com elementos do tipo  $a_{ij} = P(\omega_j(t+1) | \omega_i(t))$ , um conjunto de elementos observáveis (emissões)  $V^T = \{v(1), v(2), \dots, v(T)\}$  e uma matriz de probabilidade de emitir um observável com elementos do tipo  $b_{jk} = P(v_k(t) | \omega_j(t))$ .

Figura 19 - Modelo oculto de Markov com três unidades ocultas, suas transições de estado e as emissões visíveis em vermelho.



Fonte: Duda; Hart; Stork, 2000.

Assim como nos outros classificadores, o modelo oculto de Markov é treinado de forma supervisionada. O número de estados internos é configurado pelo desenvolvedor, e a partir dos dados de treinamento matrizes de probabilidades com os elementos  $a_{ij}$  e  $b_{jk}$  são estimadas a partir dos elementos visíveis  $V$ , que correspondem às características extraídas de um sinal bruto.

Uma vez treinado, um modelo oculto de Markov pode ser utilizado para determinar qual a sequência mais provável de estados ocultos que levam a uma sequência de observações  $V^T$ , ou quando vários modelos são treinados para reconhecer diferentes classes, é possível determinar a probabilidade de que uma sequência de observações  $V^T$  tenha sido gerada por um dado modelo.

### 3.5. Técnicas para a avaliação de desempenho dos classificadores

Para avaliar o desempenho de diferentes algoritmos de reconhecimento de padrões, ou de diferentes abordagens para tal tarefa, comumente calcula-se o desempenho do classificador por meio da taxa de acertos sobre os exemplares apresentados para essa avaliação. O cálculo deste índice de desempenho deve ser

feito de uma maneira que permita avaliar a capacidade de generalização do classificador, evitando o problema de sobre ajuste (em inglês, *overfitting*).

O sobre ajuste ocorre quando o aprendizado é altamente especializado sobre os dados de treinamento, fazendo com que os parâmetros livres do algoritmo de reconhecimento de padrões sejam ajustados especificamente para esses dados. Nesta condição, quando novos dados são apresentados o desempenho é muito pobre, indicando baixa capacidade de generalização (VAPNIK, 1999).

Uma técnica utilizada para a correta avaliação é a validação cruzada (em inglês, *cross validation*). Nesta técnica o processo de validação se inicia com o treinamento do classificador utilizando uma parte dos dados, e o restante é usado para validação. Após esta primeira rodada, o processo é repetido alternando os subconjuntos de dados utilizados para treinamento e validação, de modo que ao final, a média dos resultados obtidos em todas as rodadas representa o desempenho do classificador.

Na validação cruzada do tipo *k*-folds os dados são divididos aleatoriamente em *k* lotes (chamados *folds*), de tamanho igual, e contendo aproximadamente a mesma quantidade de exemplares por classe. Com isso, a cada repetição, o treinamento é realizado com *k-1 folds*, e a validação com a parte complementar dos dados, que corresponde ao *fold* remanescente.

## 4. Metodologia

Para alcançar os objetivos desta pesquisa, os movimentos realizados por um indivíduo foram monitorados por meio de um acelerômetro acoplado ao seu punho e foi adotada a metodologia de processamento remoto dos dados para a classificação e identificação dos mesmos. Para isso, necessitou-se planejar como os sinais gerados pelo sensor seriam enviados a um ponto remoto de processamento, como também definir quais ferramentas computacionais seriam utilizadas para o processamento dos dados e a identificação dos movimentos efetuados. Deste modo, serão descritos neste capítulo primeiramente como os sinais de aceleração foram coletados (tanto para o treinamento do classificador quanto para a utilização do sistema), e também como foram transmitidos para o local de processamento; e em seguida será apresentado como os dados foram remotamente processados e classificados para fornecer, como resultado final, o reconhecimento dos movimentos realizados pelo indivíduo.

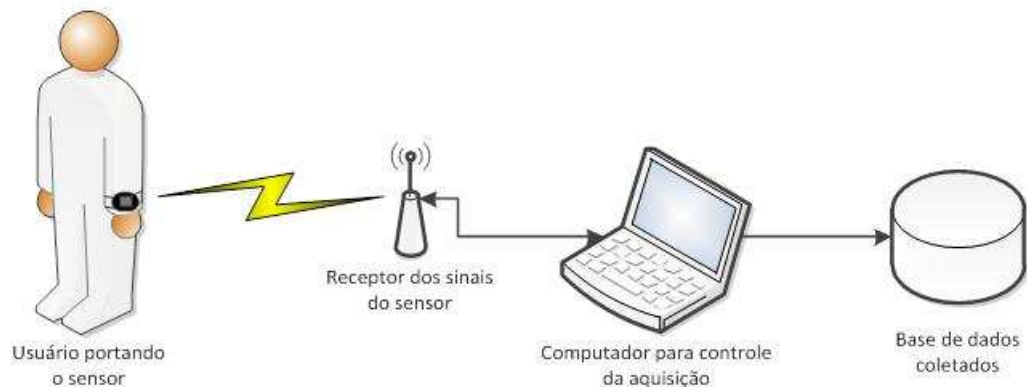
### ***4.1. A aquisição e transmissão dos sinais***

Neste item será apresentado como o sistema de aquisição foi acoplado ao corpo do usuário e como os sinais de aceleração foram transmitidos a um computador para o devido armazenamento, objetivando formar a base de dados de treinamento, como também a transmissão para uma central remota de monitoramento durante a operação do sistema.

#### **4.1.1. O sistema de aquisição**

O sistema de aquisição dos sinais de aceleração, cujo diagrama simplificado é apresentado na Figura 20, foi baseado na plataforma de desenvolvimento ez430-Chronos da Texas Instruments. Por ser um ambiente de desenvolvimento embarcado em um relógio esportivo, não houve problemas relacionados com a fixação do sensor ao punho do indivíduo, evitando-se a ocorrência de deslocamentos do sensor em relação ao corpo do indivíduo monitorado durante as movimentações, o que, conseqüentemente, facilitou a tarefa de reconhecimento de padrões.

Figura 20 - Diagrama simplificado do sistema de aquisição de dados.



Fonte: Autoria própria

A comunicação entre o relógio e o receptor foi feita através de um enlace de RF, operando na frequência de 433 MHz, que está localizada em uma faixa de frequências destinadas às aplicações ISM (em português: Industriais, Científicas e Médicas). Por ser um sistema de aquisição sem fios, sua utilização não influenciou a maneira como os movimentos foram executados, evitando-se uma possível queda de desempenho no reconhecimento. O receptor dos sinais do relógio possui uma interface de comunicação do tipo USB, apresentando-se como um periférico da classe CDC (*Communication Device Class*). Essa característica simplifica o desenvolvimento de aplicações diversas como o efetuado neste trabalho, pois a comunicação é feita através de uma porta serial virtual, sendo este modelo de comunicação muito bem difundido e documentado. Informações detalhadas podem ser obtidas em (AXELSON, 2007).

A aquisição dos sinais utilizando o dispositivo ez430-Chronos foi feita de maneira assíncrona, isto é, o envio das amostras de aceleração foi iniciado a partir de um comando específico transmitido por meio do enlace de RF. Esta tarefa somente é interrompida quando por solicitação de parada, utilizando um comando específico, ou no caso de perda da conexão entre o relógio e o receptor.

O *firmware* presente no relógio configura o acelerômetro para uma amostragem contínua dos três eixos à taxa de 100 Hz e sensibilidade de  $\pm 2$  g. Apesar da taxa de amostragem configurada no sensor ser de 100 Hz, apenas um terço das amostras foram transmitidas ao computador remoto, resultando em uma taxa de amostragem efetiva de 33 Hz. Esta taxa de amostragem é suficiente para a monitoração dos movimentos humanos mais rotineiros, além de manter o consumo de energia em um nível reduzido, aumentando a autonomia do relógio.

### 4.1.2. Amostragem dos movimentos

A proposta deste trabalho foi utilizar um algoritmo de reconhecimento de padrões baseado em aprendizado supervisionado, ou seja, o ajuste dos parâmetros livres relacionados a cada tipo de algoritmo foi feito a partir de uma base de dados de treinamento. Essa base de dados foi formada a partir de exemplos de sinais obtidos durante todas as diferentes movimentações previstas para o reconhecimento, cada qual associado à informação da classificação esperada, constituindo pares de informações do tipo entrada e saída esperados.

Tabela 1 - Lista de movimentações que o sistema reconhece.

Movimentos reconhecidos	
1	Deitado
2	Sentado
3	Em pé
4	Andando
5	Correndo
6	Subindo escada
7	Descendo escada
8	Trabalhando no computador

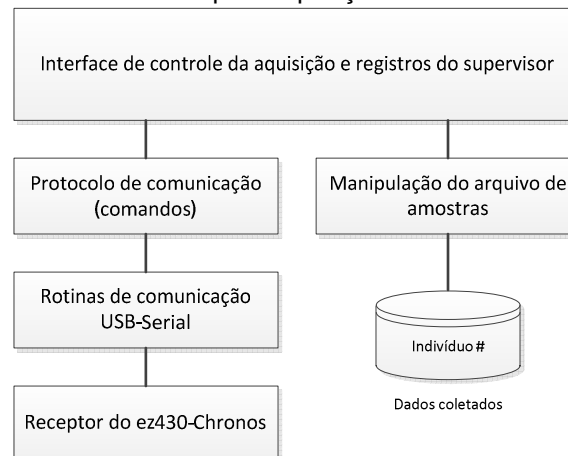
A formação da base de treinamento iniciou-se com a coleta de sinais de aceleração “rotulados”, realizada utilizando também o relógio ez430-Chronos, instalado no punho dominante de indivíduos convidados a executar uma sequência de movimentações previamente planejadas e supervisionadas por outro indivíduo, que foi responsável por registrar (rotular) qual a movimentação em curso para cada instante da aquisição de dados. No instante correspondente à formação da base de treinamento, o receptor foi conectado diretamente a um computador dedicado a esta tarefa.

Levando em consideração que este trabalho utilizou um único acelerômetro posicionado no punho para monitorar as diferentes movimentações, somente as movimentações mais básicas e rotineiras (listadas na Tabela 1) foram consideradas para a formação da base de dados de treinamento e posterior reconhecimento pelo sistema desenvolvido neste trabalho.

O registro manual (anotação) feito pelo indivíduo supervisor, contendo o horário de início, do fim e o tipo de atividade executada, poderia resultar em alguns erros ou imprecisões ao sincronizar as anotações com os sinais coletados. De modo a evitar esse tipo de problema, as rotinas de controle da aquisição de dados, a

recepção e armazenamento dos sinais, e uma interface gráfica que auxiliasse nos registros do supervisor foram integradas em um único software, cuja estrutura funcional é ilustrada na Figura 21.

Figura 21 - Diagrama funcional do software para aquisição dos movimentos.



Fonte: autoria própria.

As informações recebidas do sensor e do usuário supervisor foram armazenadas pelo software em um arquivo de dados, contendo um índice de contagem de amostras, a data e hora em que a amostra foi obtida, os valores da aceleração nos eixos x, y e z e a classificação esperada.

#### 4.1.3. Servidor pessoal

Diferentemente do modo como a aquisição dos sinais para a formação da base de dados de treinamento foi efetuada, planejou-se que as aquisições deveriam ser realizadas de maneira automática e sem intervenção do usuário durante a operação do sistema, de modo que ele não tivesse preocupação alguma com essa tarefa. Nesta fase, denominada operação (situação tal em que o algoritmo de reconhecimento de padrões já fora treinado e oferecendo bom desempenho), os sinais gerados foram enviados a um computador, aqui denominado “servidor pessoal”, localizado no domicílio do indivíduo monitorado ou no ambiente conveniente para monitoramento. Assim, as amostras ao serem recebidas localmente podem ser enviadas, por meio de uma rede de comunicação (rede local, internet, dentre outras), para uma central de monitoramento remota, onde profissionais responsáveis pelo acompanhamento de um ou mais indivíduos podem analisar os dados processados.



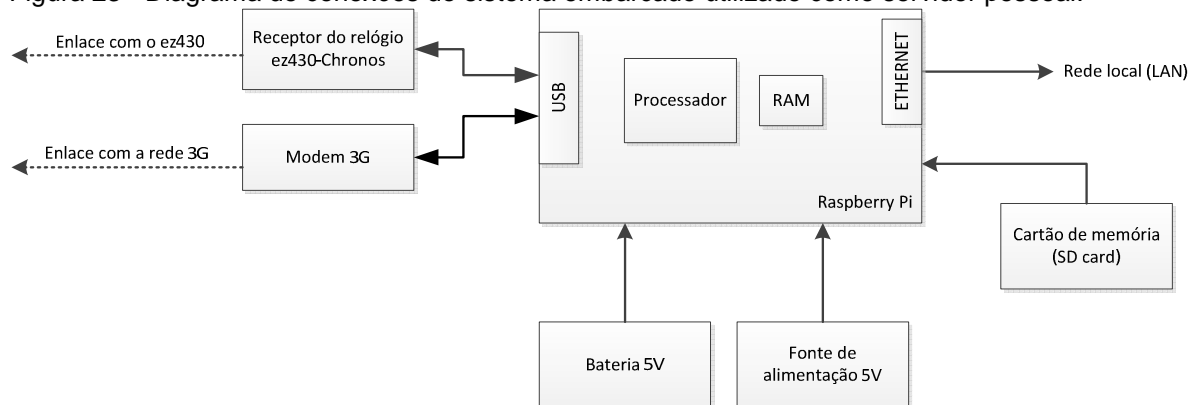
Neste sentido, para que o servidor local tivesse baixo custo, simplicidade de uso e instalação, assim como boa autonomia quando operando sobre baterias, a implementação de hardware foi baseada em um sistema embarcado denominado *Raspberry Pi* (ilustrado na Figura 22), que corresponde a um mini computador com processador ARM9, 512MB de memória RAM, interfaces de comunicação USB e Ethernet, e suporte ao sistema operacional Linux (RASPBERRY PI, 2013).

Figura 22 - Sistema embarcado Raspberry Pi.



Fonte: Raspberry Pi (2013).

Figura 23 - Diagrama de conexões do sistema embarcado utilizado como servidor pessoal.



Fonte: Autoria própria.

Desta maneira, o receptor do relógio ez430-Chronos foi conectado diretamente à placa Raspberry Pi, assim como um modem 3G que, no caso de necessidade, tornaria possível a conectividade entre o servidor pessoal e a central de monitoramento remoto por meio de redes de celular. Ainda no que se refere à conectividade, a placa foi conectada a uma rede local ethernet, que neste momento tornou-se o canal exclusivo de comunicação do sistema. A Figura 23 apresenta um

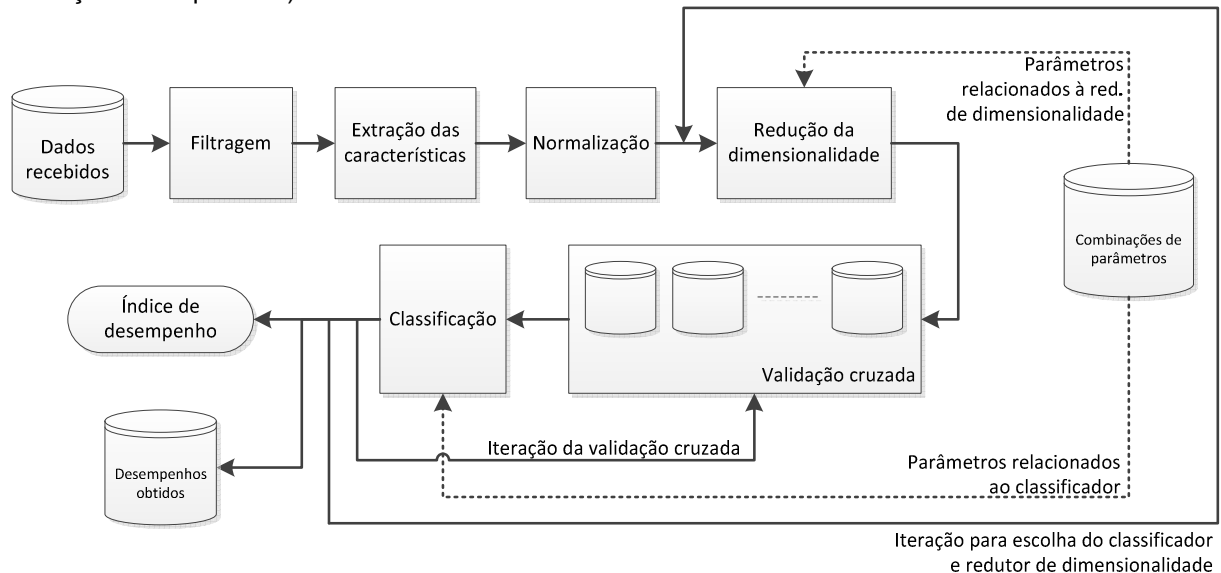
diagrama detalhado de conexões ao hardware embarcado, apresentado os blocos já discutidos dentre outros.

## 4.2. Processamento e classificação dos sinais

A partir dos dados transmitidos pelo sistema de aquisição, foram definidas as etapas necessárias para o reconhecimento dos movimentos, que englobam tanto as fases de treinamento e definição da arquitetura (indicadas no diagrama de blocos da Figura 24), quanto a fase de operação do sistema (indicadas na Figura 25). As distinções relativas a cada fase serão discutidas nos próximos itens deste capítulo durante a abordagem dos elementos afetados.


Para a implementação de cada uma das etapas indicadas nos diagramas, foi utilizada principalmente a ferramenta computacional MATLAB (com o *toolbox* de redes neurais) e a biblioteca de software libSVM. A função e a implementação de cada uma das etapas também serão discutidas a seguir.

Figura 24 - Diagrama de blocos do processamento e classificação dos sinais (fase de treinamento e definição da arquitetura).



Fonte: Autoria própria.

Figura 25 - Diagrama de blocos do processamento e classificação dos sinais (fase de operação)



Fonte: Autoria própria.


### 4.2.1. Filtragem

A filtragem dos sinais de aceleração com um filtro passa-baixas evita a presença de ruídos de alta frequência e também a ocorrência de erros aleatórios durante a amostragem, suavizando o sinal. Por outro lado, a filtragem com um filtro passa-altas pode ser aplicada para separar a componente correspondente à aceleração do corpo do sinal total de aceleração, que inclui também a aceleração gravitacional.

Deste modo, um filtro passa-baixa muito simples, do tipo média móvel, foi utilizado sobre os dados brutos de aceleração. Após a suavização dos sinais com este primeiro filtro, os sinais de aceleração foram submetidos a um filtro passa-altas para eliminação da aceleração gravitacional, que corresponde à componente DC (0 Hz). A fração resultante do sinal, contendo apenas a aceleração do corpo, foi utilizada para determinar se o sinal corresponde a uma atividade estática, ou postura (em pé, sentado, deitado ou trabalhando no computador), ou a uma atividade dinâmica (caminhar, correr, subir ou descer escadas).

A Figura 26 apresenta o diagrama de blocos da filtragem dos sinais de movimentação, contendo um filtro passa-baixas média-móvel com 3 coeficientes, e um filtro elíptico passa-altas com frequência de corte em 0,5 Hz.

Figura 26 - Diagrama da estrutura responsável pela filtragem dos sinais



Fonte: Autoria própria

### 4.2.2. Segmentação dos dados

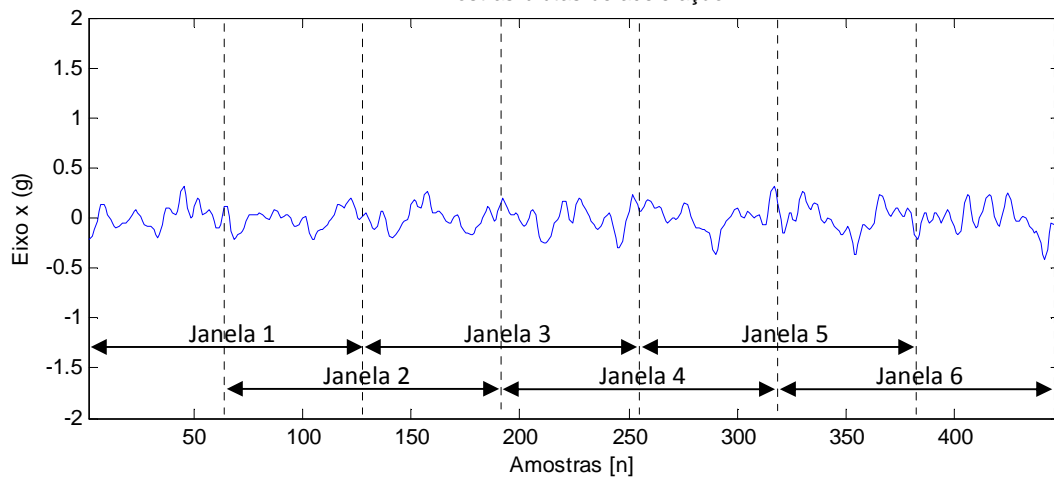
Para que as amostras de aceleração previamente coletadas sejam processadas e classificadas, primeiramente é necessário que o conjunto de dados seja segmentado em pequenas quantidades, as quais recebem o nome de janela de amostras.

A escolha do tamanho da janela de amostras foi feita sob uma relação de compromisso entre informação e resolução, pois quanto maior o comprimento, maior a quantidade de informações sobre a movimentação, porém menor a resolução do

classificador, pois um único rótulo de classe é atribuído a cada janela, e se esta for muito longa diferentes movimentações poderiam estar contidas em um mesmo intervalo (GYLLENSTEN, 2010).

Assim, como mostra a Figura 27, foram utilizadas 128 amostras por janela para a segmentação dos sinais, e cada janela correspondeu a um intervalo de 3,88 s contendo sinais relativos às movimentações do indivíduo e com uma sobreposição de 50%, ou seja, cada janela possui metade das amostras da janela anterior, evitando-se com isso que alguma atividade localizada na junção entre duas janelas fosse perdida.

Figura 27 - Segmentação dos dados em janelas de 128 amostras com 50% de sobreposição  
Amostras brutas de aceleração



Fonte: Autoria própria

#### 4.2.3. Extração de características

Após a segmentação dos dados em janelas de amostras, estas devem ser primeiramente processadas antes da sua submissão à entrada do algoritmo de reconhecimento de padrões. Neste trabalho foram extraídas algumas características das janelas de amostras comumente utilizadas no reconhecimento de sinais, calculadas tanto no domínio do tempo quanto da frequência.

As características listadas a seguir envolvem as amostras no domínio do tempo e foram obtidas diretamente das janelas de amostras:

Média:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (4.1)$$

Área do módulo (SMA):

$$SMA(\mathbf{x}, \mathbf{y}, \mathbf{z}) = \sum_{i=1}^N (|x_i| + |y_i| + |z_i|) \quad (4.2)$$

Desvio padrão:

$$\mathbf{x}_{dp} = \sqrt{\frac{1}{(N-1)} \sum_{i=1}^N (x_i - \bar{\mathbf{x}})^2} \quad (4.3)$$

Obliquidade:

$$s(\mathbf{x}) = \frac{\frac{1}{N} \sum_{n=1}^N (x_i - \bar{\mathbf{x}})^3}{\left( \frac{1}{N} \sum_{n=1}^N (x_i - \bar{\mathbf{x}})^2 \right)^3} \quad (4.4)$$

Curtose:

$$k(\mathbf{x}) = \frac{\frac{1}{N} \sum_{n=1}^N (x_i - \bar{\mathbf{x}})^4}{\left( \frac{1}{N} \sum_{n=1}^N (x_i - \bar{\mathbf{x}})^2 \right)^2} \quad (4.5)$$

Correlação:

$$\rho(\mathbf{x}, \mathbf{y}) = \frac{\sum_{n=1}^N (x_i - \bar{\mathbf{x}})(y_i - \bar{\mathbf{y}})}{\sqrt{\sum_{n=1}^N (x_i - \bar{\mathbf{x}})^2} \sqrt{\sum_{n=1}^N (y_i - \bar{\mathbf{y}})^2}} \quad (4.6)$$

Varição:

$$\text{var}(\mathbf{x}) = \max_i(x_i) - \min_i(x_i) \quad (4.7)$$

Quantidade de amostras sem alteração:

*“Contagem do número máximo de amostras consecutivas sem mudança, ou quando a mudança é inferior a um valor de tolerância.”*

Aplicando a transformada discreta de Fourier nas janelas de amostras, dada pela equação (4.8), a sequência de amostras discretas no domínio do tempo é transformada para o domínio da frequência (OPPENHEIM e SCHAFER, 2009), permitindo o cálculo das características listadas a seguir, que também foram utilizadas neste trabalho:

$$X(k) = \sum_{i=1}^N x[n] e^{-\frac{j2\pi kn}{N}} \quad (4.8)$$

Energia média:

$$E(k) = \sum_{k=m}^n X^2(k) \quad (4.9)$$

Entropia espectral:

$$H(x) = -\sum_{k=1}^N X(k) \log(X(k)) \quad (4.10)$$

Máxima magnitude, e frequência da máxima magnitude:

$$M(k) = \max_i (|X(k_i)|) \quad (4.11)$$

É importante ressaltar que apenas as características “SMA” e “Energia média” resultam em um único valor, pois o seu cálculo já envolve as amostras relacionadas aos três eixos simultaneamente. Para todas as outras características, três valores foram obtidos, correspondendo aos sinais oriundos dos eixos x, y e z do sensor acelerômetro.

#### 4.2.4. Normalização das características

Visando normalizar os valores das características extraídas dos sinais de aceleração, já que poderiam se apresentar em escalas muito diferentes entre si, as equações (4.12), (4.13) e (4.14) foram aplicadas para garantir média nula e variância unitária. Este processo é necessário para que as diferenças significativas de valores não influenciem as funções de custo utilizadas no treinamento do algoritmo de reconhecimento de padrões, tornando as características de maior valor absoluto mais significativas, embora isso não reflita a sua significância na classificação (THEODORIDIS e KOUTROUMBAS, 2009).

$$\hat{x}_{ik} = \frac{x_{ik} - \bar{x}_k}{\sigma_k} \quad (4.12)$$

$$\bar{x}_k = \frac{1}{N} \sum_{i=1}^N x_{ik} \quad (4.13)$$

$$\sigma_k^2 = \frac{1}{N-1} \sum_{i=1}^N (x_{ik} - \bar{x}_k)^2 \quad (4.14)$$

A equação (4.12) descreve o processo de normalização que foi aplicado para as N observações da k-ésima característica extraída, utilizando a média e a variância calculadas conforme descrevem as equações (4.13) e (4.14) respectivamente.

#### **4.2.5. Redução de dimensionalidade**

Após os processos de extração e normalização, conduziu-se a etapa de redução de dimensionalidade do espaço formado por essas características extraídas sobre os sinais de aceleração. Deste modo, o padrão submetido à entrada do classificador possuiu maior capacidade discriminatória dos dados originais, facilitando o processo de aprendizado e conseqüentemente o desempenho final do classificador.

Durante o processo exploratório de busca pelos parâmetros que resultaram na melhor configuração de cada algoritmo de classificação (será detalhado adiante no item 4.3 deste trabalho), foi variada também a maneira pela qual as características foram selecionadas, ou transformadas, de modo a reduzir a sua dimensionalidade.

O processo de avaliação envolveu a utilização da técnica de seleção de características por FDR (*Fisher's Discriminant Ratio*), como também a redução da dimensionalidade por meio da PCA (Principal Component Analysis), com o objetivo de avaliar a influência de cada técnica no desempenho final do classificador.

O critério para seleção do número de características (no caso do FDR), ou do número de combinações lineares (no caso da PCA) que foi utilizado para a classificação, foi o de manter os elementos acima da média geral dos escores (FDR) ou auto-valores (PCA), conforme já abordado no item 3.3 deste trabalho.

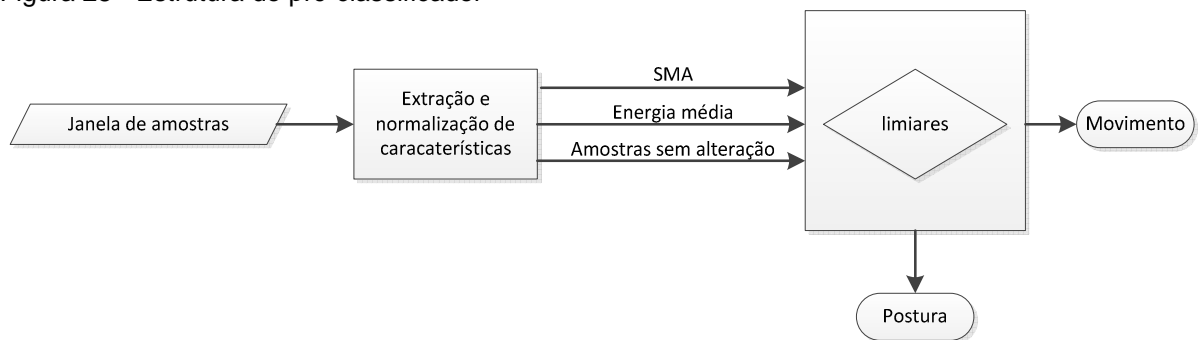
#### **4.2.6. Classificação dos sinais**

Para a classificação dos sinais processados foram utilizadas algumas técnicas de reconhecimento de padrões. A revisão bibliográfica apresentada no capítulo 3 lista algumas técnicas utilizadas em trabalhos de reconhecimento de sinais de aceleração, e dentre essas técnicas foram selecionadas as redes neurais artificiais MLP, as máquinas de vetores de suporte e a técnica de k vizinhos mais próximos para avaliação e definição do classificador utilizado neste trabalho. Cada uma dessas três técnicas foi avaliada em duas diferentes abordagens: na primeira, um único classificador foi utilizado para identificar todos os movimentos; e na segunda foi utilizado um classificador dedicado às movimentações e outro às posturas.

#### 4.2.6.1. Estrutura dos classificadores

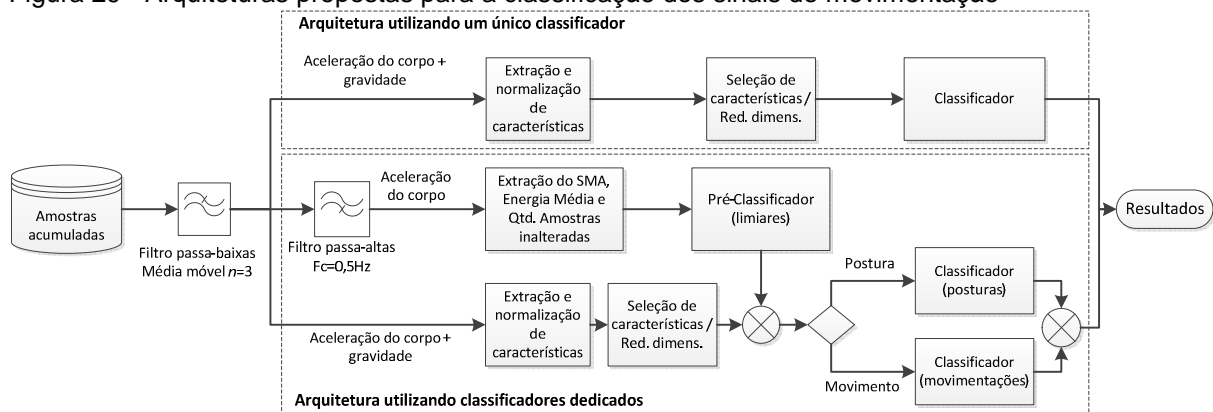
O sistema de reconhecimento baseado em um único classificador operou tanto com amostras de aceleração relacionadas a posturas quanto a movimentações. Deste modo, o sistema utilizou-se dos sinais resultantes da filtragem passa-baixas apenas, pois este sinal continha informações da dinâmica da movimentação como também os níveis DC relacionados às posturas (projeção da aceleração gravitacional sobre os eixos). Com isso, os dados de saída da etapa de redução de dimensionalidade foram diretamente aplicados ao classificador, sem necessidade de prévia separação ou pré-classificação.

Figura 28 - Estrutura do pré-classificador



Fonte: Autoria própria

Figura 29 - Arquiteturas propostas para a classificação dos sinais de movimentação



Fonte: Autoria própria

Com objetivo de facilitar o trabalho do algoritmo de classificação dos sinais para o reconhecimento de movimentos e melhorar o desempenho geral de reconhecimento, os trabalhos de (KARANTONIS, 2006; MATHIE, 2003 e YANG; WANG; CHEN, 2008) empregaram um classificador específico para as movimentações, e outro para as posturas. Essa abordagem também foi avaliada neste trabalho por meio do uso dos sinais filtrados tanto pelo filtro passa-baixas



quanto pelo filtro passa-altas. O sinal resultante deste segundo filtro foi submetido a um pré-classificador específico (visto na Figura 28) baseado em limiares do valor da energia média, área do módulo e a quantidade consecutiva de amostras sem alteração. Esta etapa de pré-classificação permitiu definir qual classificador deveria ser utilizado na análise dos sinais provenientes do filtro passa-baixas para a identificação dos movimentos contidos em cada uma das janelas.

As duas arquiteturas avaliadas estão ilustradas na Figura 29.

#### **4.2.6.2. Redes neurais artificiais**

As avaliações das técnicas de reconhecimento de padrões envolveram as redes neurais artificiais de arquitetura MLP. Foram utilizadas funções de transferência do tipo sigmóide nas camadas de entrada e oculta(s) da rede, e para o treinamento foi utilizada uma variação do algoritmo de retro propagação de erros denominada *Resilient Backpropagation* (também chamado de “*Rprop*”), que adicionou uma heurística de aprendizado ao algoritmo padrão, permitindo uma convergência mais rápida durante o treinamento.

Em ambas as arquiteturas propostas, a rede neural artificial recebeu em sua entrada um vetor correspondente às características remanescentes após a redução de dimensionalidade, e apresentou em sua saída um vetor de dimensão igual ao número de movimentos reconhecidos pelo sistema, onde o valor “1” esteve presente na saída correspondente à classe reconhecida, enquanto as saídas remanescentes continham o valor “-1”.

Para efetuar o treinamento e avaliação da rede neural artificial, 70% da base de dados de treinamento foram destinados ao treinamento e 30% destinados ao teste e validação, e foi utilizado o conceito de parada antecipada (utilizando os dados de validação) para evitar a ocorrência de *overfitting*.

#### **4.2.6.3. Máquinas de vetores de suporte**

As máquinas de vetores de suporte foram avaliadas e utilizadas em um arranjo “um-contra-um”, e com um *kernel* do tipo RBF (*Radial basis function*) para classificação não-linear.

A implementação (treinamento e posterior utilização) dos classificadores baseados em SVM foi feita utilizando uma biblioteca de software denominada

LibSVM, que pode ser integrada tanto ao ambiente MATLAB, quanto a aplicativos desenvolvidos em diversas linguagens de programação nos sistemas operacionais Windows e Linux.

#### **4.2.6.4. K-vizinhos mais próximos**

O algoritmo de reconhecimento de padrões k-vizinhos mais próximos não necessitou de treinamento, como já explicitado anteriormente, pois é baseado em um algoritmo de busca e contagem da “maioria de votos” (k-vizinhos) para uma determinada classe baseado na presença de pontos de treinamento ao redor do ponto que se deseja classificar. Deste modo, o algoritmo recebeu um padrão diretamente da saída da redução de dimensionalidade e efetuou a classificação utilizando todos os dados disponibilizados no seu “espaço de treinamento”.

### ***4.3. Avaliação do desempenho dos classificadores***

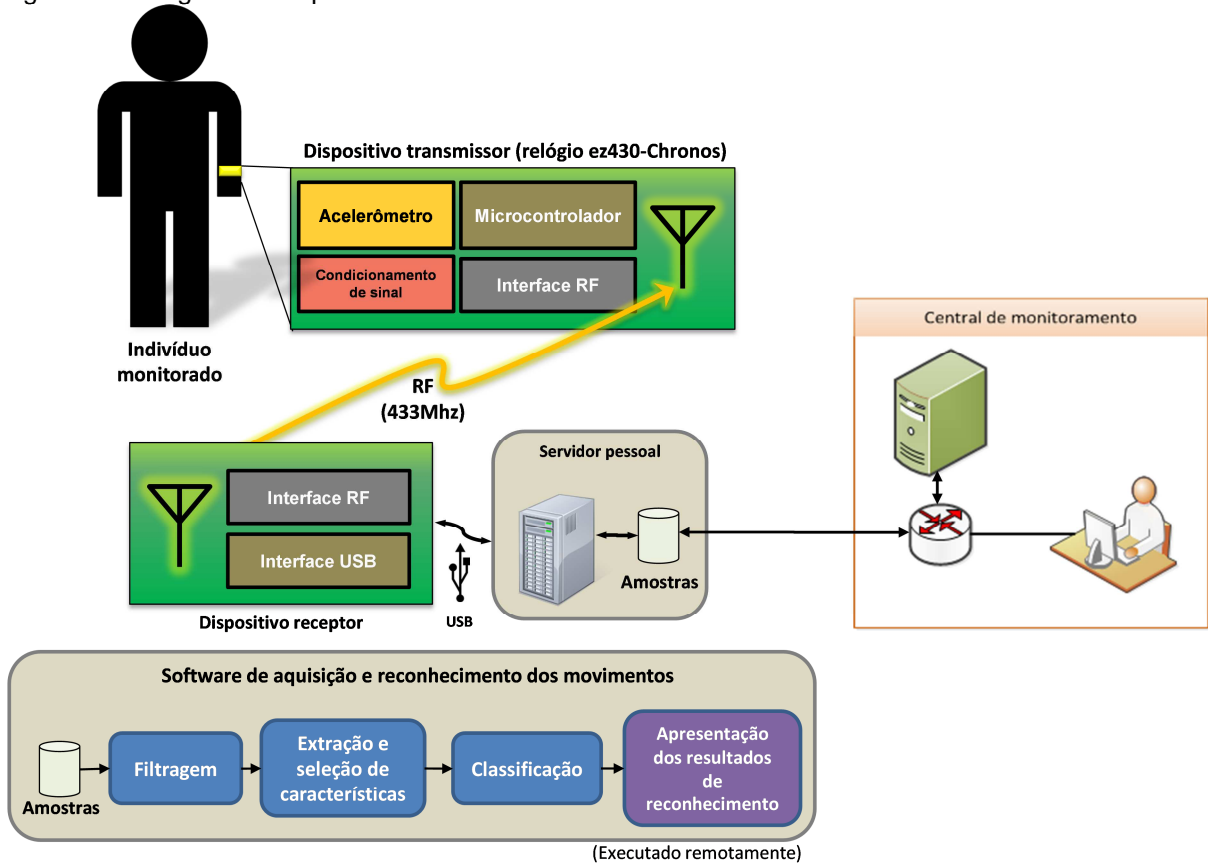
Além da diferença estrutural, inerente a cada arquitetura de classificação, a avaliação de desempenho envolveu também a permutação de valores dos parâmetros relacionados a cada técnica de inteligência computacional, ou seja, as redes neurais sofreram variações na quantidade de camadas ocultas (uma ou duas) e na quantidade de neurônios por camada (de 10 a 30), os classificadores kNN sofreram variação na quantidade de "k" vizinhos (de 1 a 10) e, por fim, as SVMs sofreram a variação dos parâmetros  $c$  (de  $2^{-5}$  a  $2^{15}$ ) e  $\gamma$  ( $2^{-5}$  a  $2^3$ ) do kernel RBF.

Para obter-se uma medida mais confiável do desempenho de cada configuração do classificador, e principalmente sobre a sua capacidade de generalização, a técnica de validação cruzada "k-fold" com  $k = 5$  foi aplicada. Deste modo, para cada configuração, os dados foram divididos em cinco conjuntos (*folds*), de mesmo tamanho e mutuamente exclusivos e, a cada ensaio, quatro foram utilizados para treinamento e um para teste. Após a realização dos cinco ensaios alternando os conjuntos, a métrica de desempenho geral foi calculada por meio de uma média dos desempenhos individuais em 10 rodadas de avaliação.

Após a busca exploratória pelo melhor desempenho, avaliando as diferentes técnicas de reconhecimento de padrões e de redução de dimensionalidade, a

configuração de melhor resultado foi selecionada para compor o sistema final, cujo diagrama estrutural é apresentado na Figura 30.

Figura 30 - Diagrama completo do sistema de reconhecimento de movimentos humanos




Fonte: Autoria própria.

## 5. Resultados

Este capítulo apresenta os resultados obtidos com a realização prática da metodologia explicitada no capítulo anterior. Primeiramente será apresentado o arranjo experimental desenvolvido para a aquisição de sinais, tanto para a formação da base de dados para treinamento, quanto para a operação do sistema; em seguida serão apresentados os sinais coletados durante o experimento, permitindo uma visão geral dos mesmos e suas diferentes características entre as atividades reconhecidas; serão também apresentados os resultados de desempenho para as duas propostas de metodologia apresentadas para a classificação dos sinais de aceleração, utilizando as três técnicas de inteligência computacional (SVM, kNN e redes MLP) mencionadas no capítulo anterior, além de duas diferentes abordagem para a seleção de características (PCA e FDR), e por fim será apresentado o software utilizado durante a operação do sistema.

### 5.1. Montagem experimental

Figura 31 - Sistema de aquisição acoplado ao punho (em destaque os eixos de orientação do acelerômetro triaxial)




Fonte: Autoria própria.

De acordo com a metodologia estabelecida, o relógio ez430-Chronos foi acoplado ao punho direito dos indivíduos voluntários para a aquisição dos sinais de aceleração, conforme ilustrado na Figura 31.

O receptor dos sinais de aceleração captados pelo relógio foi conectado à interface USB do sistema embarcado *Raspberry Pi*, na qual também foi conectada uma bateria, a rede local ethernet, um cartão de memória contendo todo o software,

além de um modem 3G que permitirá futuras conexões via rede celular. Este arranjo experimental é ilustrado na Figura 32.

Figura 32 - Solução de sistema embarcado atuando como servidor pessoal

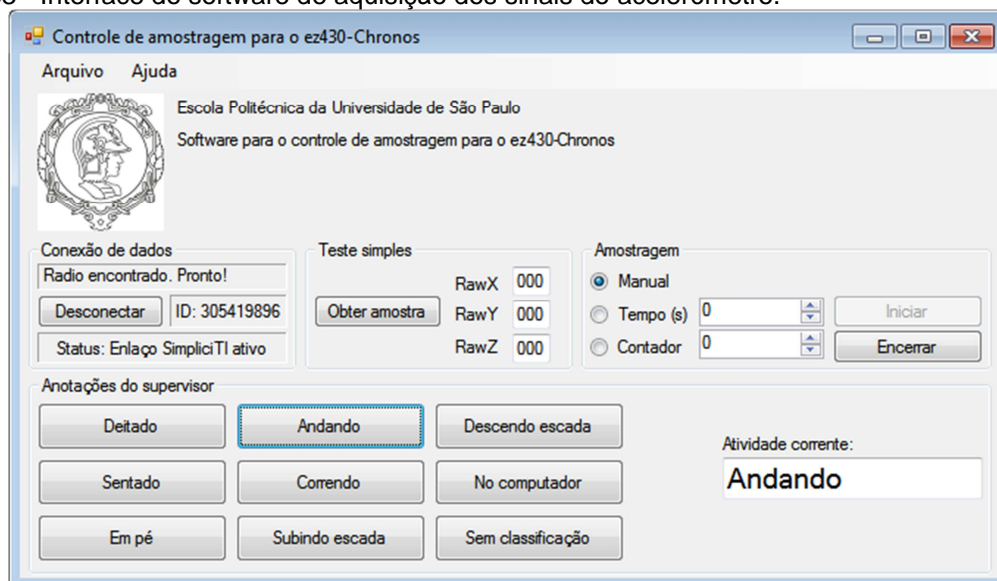


Fonte: Autoria própria

## 5.2. Software para aquisição dos sinais

Conforme os requisitos apontados no item 4.1.2, um software para aquisição e armazenamento dos sinais foi desenvolvido utilizando a linguagem de programação C#, que é uma linguagem de programação orientada a objetos desenvolvida pela Microsoft como parte do ".NET Framework". A interface do software é apresentada na Figura 33, onde nota-se uma série de botões na interface que auxiliam o supervisor a rotular a movimentação corrente durante cada instante da aquisição.

Figura 33 - Interface do software de aquisição dos sinais do acelerômetro.



Fonte: Autoria própria.


Após a aquisição de dados em diferentes momentos e com diferentes voluntários, as bases de dados armazenadas foram processadas pelo software de treinamento dos algoritmos de reconhecimento de padrões (desenvolvido em MATLAB).

### 5.3. Sinais coletados

A coleta de sinais de aceleração para o desenvolvimento e avaliação do sistema de reconhecimento envolveu seis usuários voluntários, que realizaram as oito diferentes movimentações propostas em seu ambiente domiciliar, com a supervisão de um operador utilizando o software apresentado no item anterior.

Após o término do processo, foi adquirido um total de 157696 amostras dos sinais de aceleração, que após a segmentação totalizou 2464 janelas de amostras, distribuídas entre as oito diferentes movimentações, como apresentado no gráfico da Figura 34.

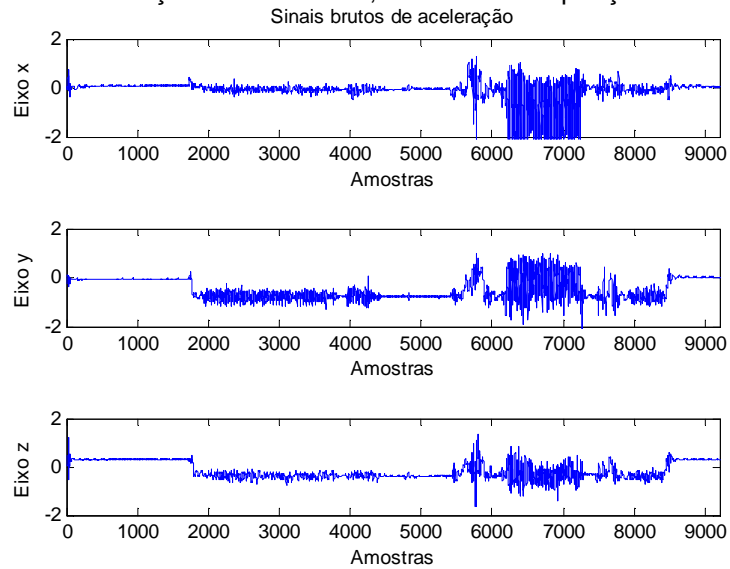
Figura 34 - Quantidade de amostras coletadas por classe de movimento



Fonte: Autoria própria.

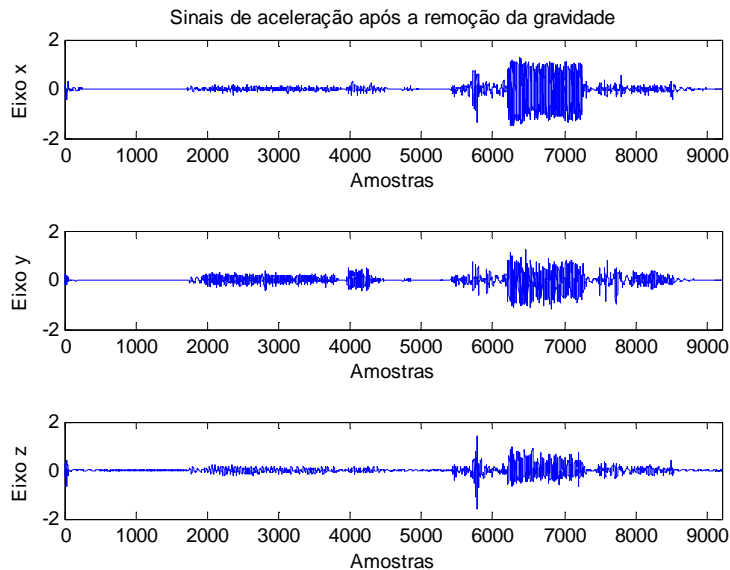
A Figura 35 apresenta um segmento dos dados coletados durante o experimento, e em seguida na Figura 36 o mesmo segmento é visto após a filtragem passa-altas com frequência de corte em 0,5 Hz para remoção da aceleração da gravidade, que é utilizado pela arquitetura onde classificadores diferentes são dedicados à classificação de posturas e movimentos (vide Figura 29).

Figura 35 - Amostras de aceleração referentes a 4,7 minutos de aquisição.



Fonte: Autoria própria.

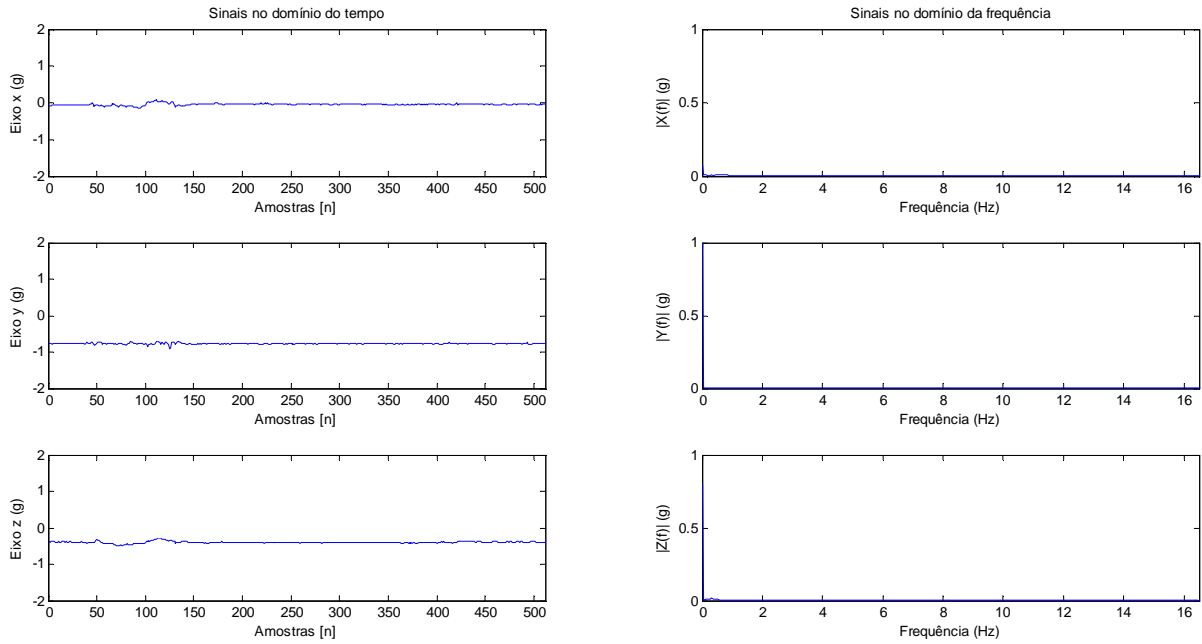
Figura 36 - Sinais após o processamento pelo filtro passa-alta utilizado na remoção da aceleração da gravidade.



Fonte: Autoria própria.

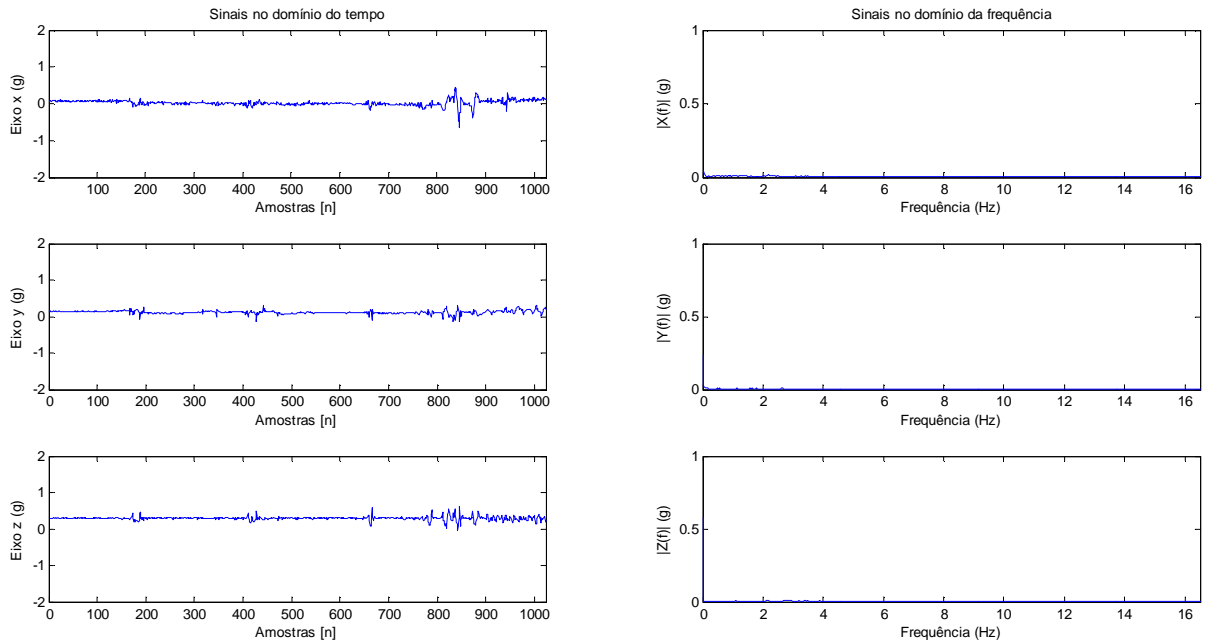
Em relação aos sinais observados para cada uma das movimentações, diferentes características podem ser observadas. Por exemplo, as classes “deitado”, “sentado” e “em pé” possuem a característica comum de serem sinais praticamente contínuos, com quase toda a energia presente na frequência 0 Hz. A classe “no computador” possui uma característica muito parecida, no entanto notam-se algumas oscilações provocadas pelo ato de movimentar o *mouse* ou digitar no teclado. Alguns sinais correspondentes a essas movimentações, que podem ser pré-classificadas como “posturas” por serem caracterizadas basicamente pela projeção da aceleração gravitacional, são vistas na Figura 37 e na Figura 38.

Figura 37 - Representação das amostras para o movimento "em pé" nos domínios do tempo e frequência.



Fonte: Autoria própria.

Figura 38 - Representação das amostras para o movimento "no computador" nos domínios do tempo e frequência.



Fonte: Autoria própria.

Já as movimentações apresentam oscilações cujas frequências e intensidades variaram de acordo com o seu tipo. Diferentemente das classes



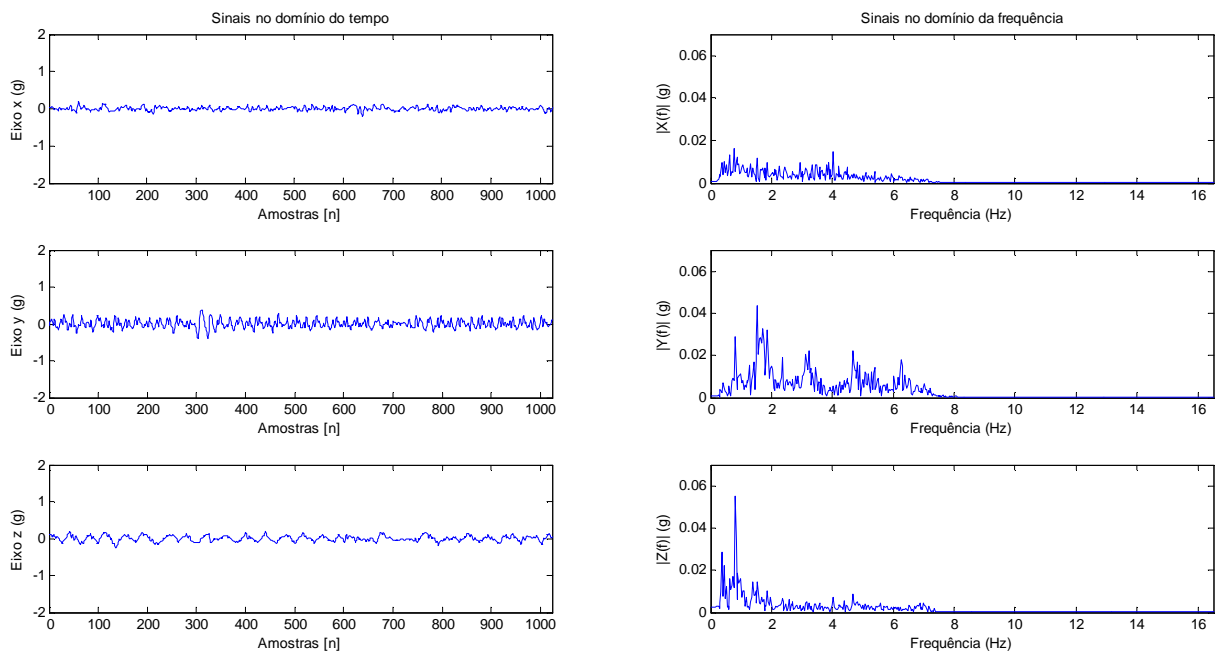
anteriores, estas não são principalmente caracterizadas pela aceleração da gravidade, desta forma um filtro passa-alta foi aplicado sobre as amostras para permitir a visualização apenas da parcela da aceleração do corpo.

Na classe “andando”, com dados adquiridos pelo acelerômetro e ilustrados graficamente na Figura 39, as oscilações apresentaram baixa intensidade (aproximando-se de no máximo 0,5 g) tanto no tempo quanto na magnitude no domínio da frequência.

Já na classe “correndo”, vista na Figura 40, as oscilações apresentaram maior intensidade, acima de 1 g, e uma magnitude no domínio da frequência que chegou a ser uma ordem de grandeza maior se comparada à classe “andando”. Outra diferença que pode ser notada é a frequência de maior magnitude, acima de 2 Hz, enquanto na classe “andando” o valor verificado foi de aproximadamente 1 Hz.

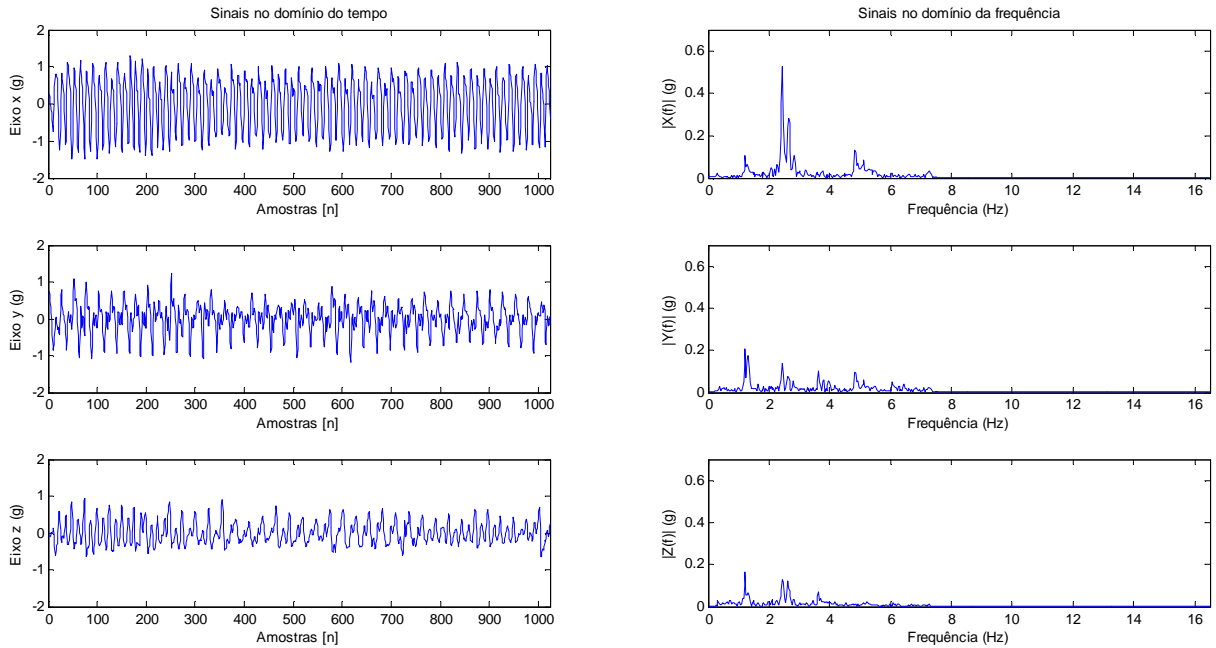
Nas classes “subindo escada” e “descendo escada”, vistas respectivamente na Figura 41 e na Figura 42, oscilações de aceleração foram novamente verificadas assim como alguns “saltos” no sinal, correspondentes à transição de um degrau para outro.

Figura 39 - Representação das amostras para o movimento "andando" nos domínios do tempo e frequência.



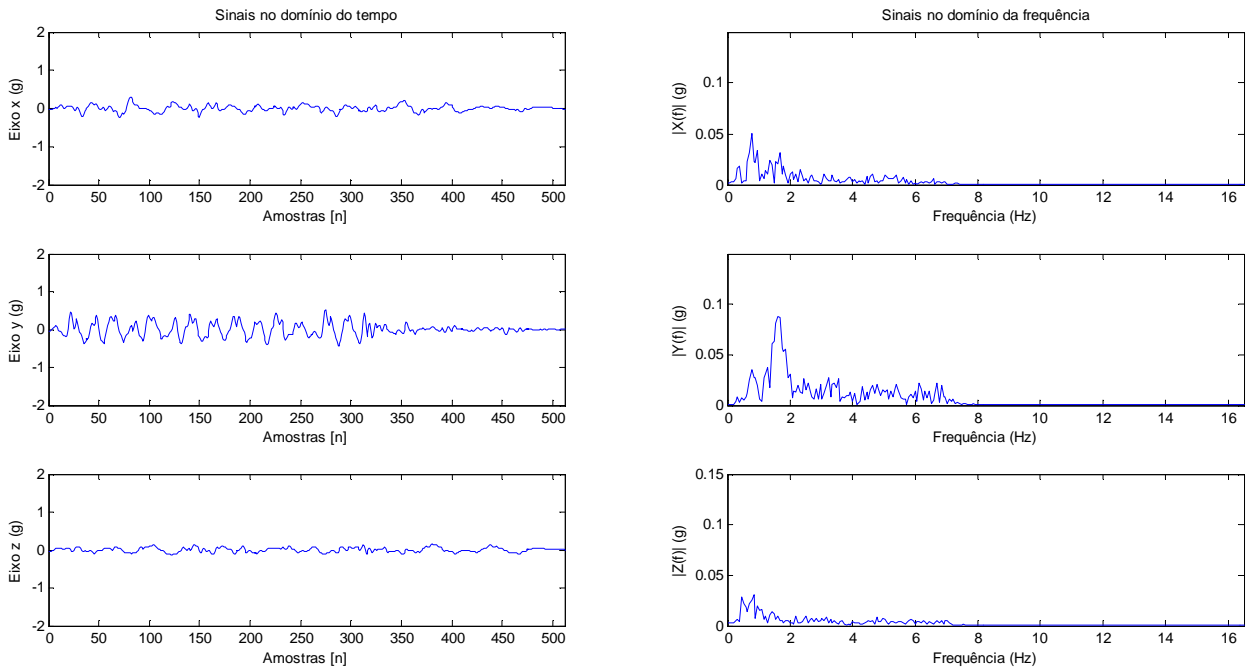
Fonte: Autoria própria.

Figura 40 - Representação das amostras para o movimento "correndo" nos domínios do tempo e frequência.



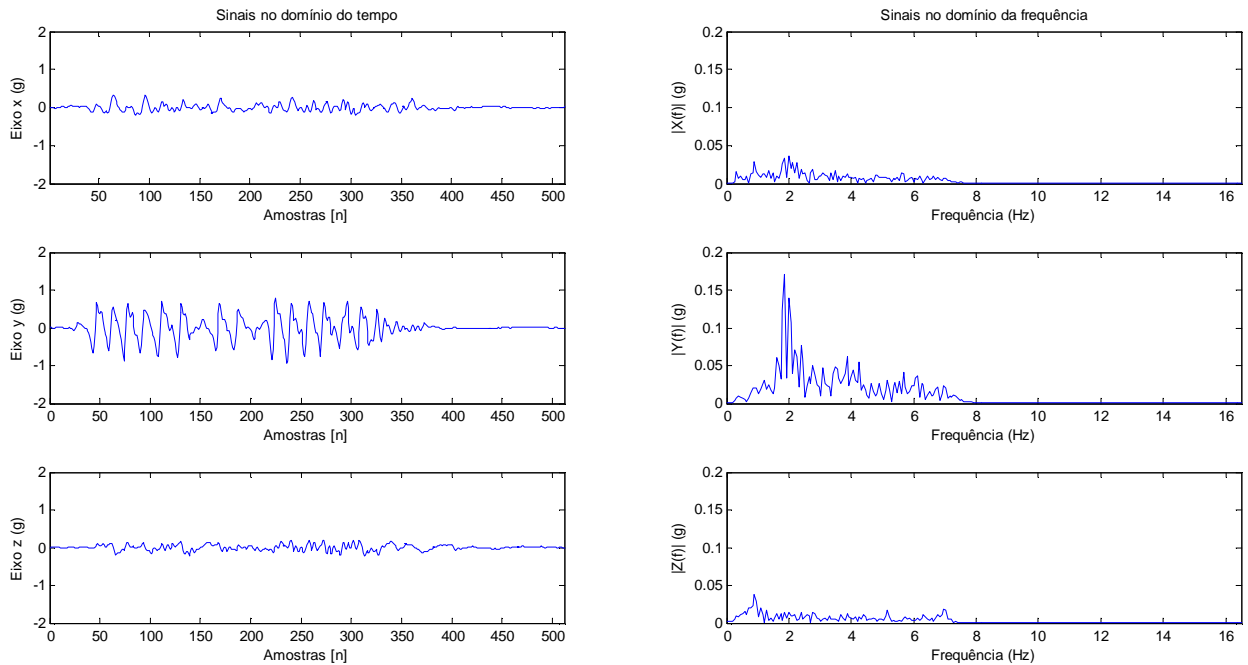
Fonte: Autoria própria.

Figura 41 - Representação das amostras para o movimento "subindo escada" nos domínios do tempo e frequência.



Fonte: Autoria própria.

Figura 42 - Representação das amostras para o movimento "descendo escada" nos domínios do tempo e frequência.



Fonte: Autoria própria.

#### 5.4. Desempenho utilizando um único classificador

A Tabela 2 apresenta os resultados obtidos com a análise exploratória utilizando um único classificador e a variação dos diferentes parâmetros relacionados às RNAs, SVMs e aos kNN, como também o emprego da PCA ou FDR. O melhor desempenho geral, correspondente a 93,47%, foi alcançado utilizando as características selecionadas por FDR, e um classificador baseado em SVM com kernel RBF e  $c = 2^{-1}$  e  $\gamma = 2^{-3}$ .

O desempenho individual para cada uma das atividades, verificado com o uso da configuração de melhor desempenho geral (FDR+SVM), pode ser visto através da matriz confusão presentes na Tabela 3, onde se verifica índices (ou taxas de acerto) acima de 88%. O número identificador de cada atividade pode ser consultado na Tabela 1 no item 4.1.2 deste trabalho.

Tabela 2 - Avaliação do desempenho utilizando um único classificador

	MLP	kNN	SVM
<b>FDR</b>	90,14%	91,10%	93,47%
<b>PCA</b>	90,91%	84,01%	91,03%

Tabela 3 - Matriz confusão para a arquitetura utilizando um único classificador

	Classe real								Taxa de acerto	
	1	2	3	4	5	6	7	8		
Classe predita	1	304	3	1	1	0	0	0	9	96,20%
	2	1	385	0	2	0	0	0	16	93,22%
	3	1	0	325	1	1	0	0	0	97,31%
	4	2	2	3	298	0	18	9	2	88,96%
	5	1	1	1	4	219	0	0	0	99,55%
	6	0	0	2	20	0	214	9	0	88,07%
	7	1	0	2	9	0	11	216	0	92,31%
	8	6	22	0	0	0	0	0	342	92,68%

### 5.5. Desempenho utilizando dois classificadores

O sistema composto por classificadores independentes para posturas e movimentações foi avaliado de maneira idêntica ao sistema anterior, porém uma primeira etapa, correspondente à divisão das amostras entre as duas categorias, foi realizada por meio de valores de limiares.

Os valores dos limiares, que podem ser vistos na Tabela 4, foram obtidos experimentalmente, observando os valores das características para as diferentes classes.

Tabela 4 - Limiares utilizados para pré-classificação

Característica	Valor do limiar
SMA	> 0,1575 g
Energia média	> 0,1732 g <sup>2</sup>
Sequência sem movimento	< 35 amostras

Tabela 5 - Avaliação do desempenho utilizando classificadores dedicados

	MLP	kNN	SVM
<b>FDR</b>	87,34%	88,20%	90,63%
<b>PCA</b>	87,91%	80,15%	88,76%

A Tabela 5 apresenta os resultados obtidos com a análise exploratória utilizando dois classificadores, novamente com a variação dos diferentes parâmetros relacionados às RNAs, SVMs e aos kNN, como também o emprego da PCA ou FDR. O melhor desempenho geral, de 90,63%, foi obtido também com as características

selecionadas por FDR e um classificador baseado em SVM kernel RBF com  $c = 2^5$  e  $\gamma = 2^{-1}$ .

O desempenho de classificação individual para cada uma das classes, utilizando o classificador de melhor desempenho geral (FDR+SVM), é visto na matriz confusão apresentada na Tabela 6.

Tabela 6 - Matriz confusão para o classificador com melhor desempenho

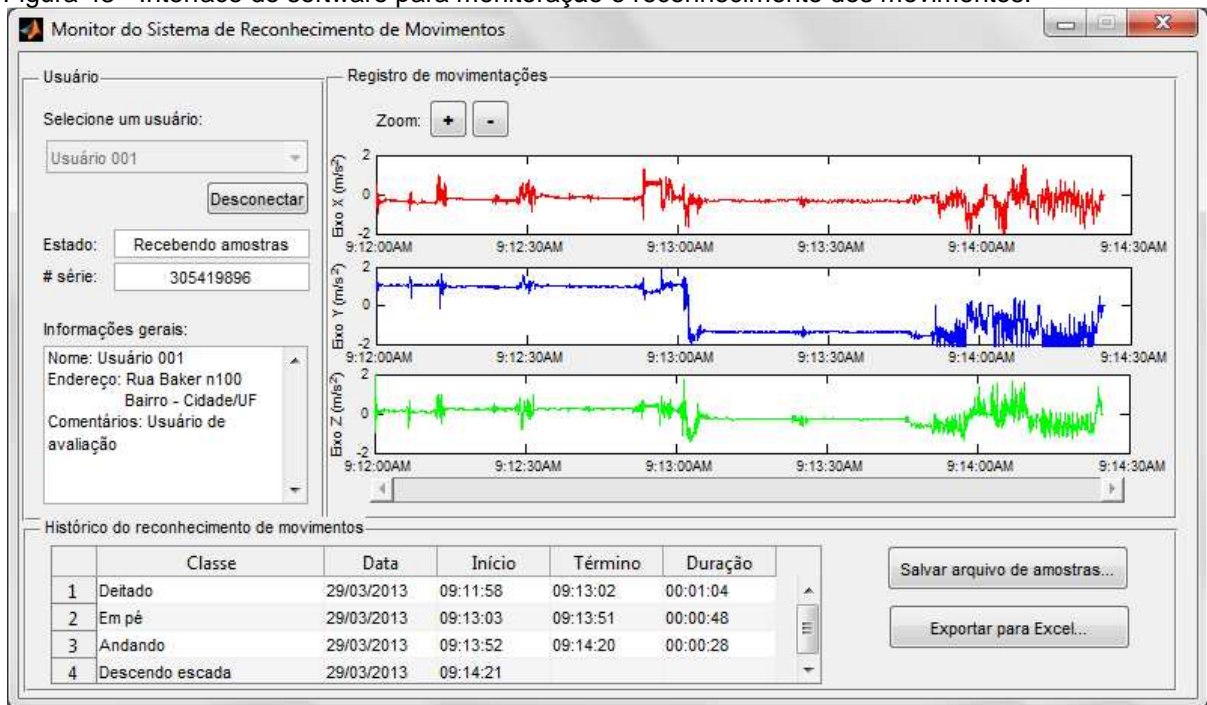
	Classe real								Taxa de acerto
	1	2	3	4	5	6	7	8	
1	297	3	1	1	0	0	0	6	93,99%
2	5	397	0	4	4	3	9	20	96,13%
3	1	0	330	32	1	20	18	1	98,80%
4	1	0	2	270	0	18	6	1	80,60%
5	5	2	0	3	215	0	0	7	97,73%
6	0	0	0	15	0	198	6	0	81,48%
7	0	0	0	7	0	3	195	0	83,33%
8	7	11	1	3	0	1	0	334	90,51%

### 5.6. Software para monitoração remota dos movimentos

Com o resultado da análise comparativa, o classificador baseado em uma única SVM foi selecionado como o mais adequado, sendo utilizado para compor o software de reconhecimento dos movimentos, cuja interface gráfica (GUI, *Graphical User Interface*) é apresentada na Figura 43.

Este software permite que agentes remotos possam acompanhar, em tempo real, as movimentações realizadas pelo usuário do relógio. A implementação atual permite apenas a recepção das amostras (encaminhadas pelo servidor pessoal) por meio da interface de rede ethernet, e efetua as etapas de processamento e reconhecimento dos movimentos localmente (no computador do supervisor), utilizando como infraestrutura de software o MATLAB e a libSVM, conforme apontado na metodologia deste trabalho.

Figura 43 - Interface do software para monitoração e reconhecimento dos movimentos.



Fonte: Autoria própria.

## 6. Conclusões

Este trabalho mostra ser possível o reconhecimento de movimentos humanos básicos através de um único acelerômetro MEMS triaxial embutido em um relógio de pulso, oferecendo uma solução que pode ser empregada em monitorações por longos períodos, sendo altamente atrativa, por exemplo, para aplicação nos ambientes de vida assistida (AAL).

Dentre as técnicas analisadas para o reconhecimento de padrões, as máquinas de vetores de suporte (SVMs), aliadas aos dados selecionados pela técnica FDR, apresentaram o melhor desempenho, chegando a 93,47% de sucesso no reconhecimento dos movimentos selecionados. Também na abordagem com um único classificador e utilizando FDR, a técnica de k-vizinhos mais próximos (kNN) apresentou um desempenho muito semelhante às SVMs, com 91,10% de sucesso no reconhecimento dos movimentos.

A técnica kNN oferece uma vantagem inicial de desempenho por não requerer treinamento, ao contrário das SVMs onde o processo demanda um grande número de interações e pode levar algum tempo para convergir. Durante a fase de teste (ou operação), os kNN podem também ser mais rápidos, mas caso o número de pontos de treinamento seja muito elevado, e com o incremento no número de vizinhos (k), a classificação pode ser tornar extremamente complexa e de alto custo computacional, devolvendo a vantagem às SVMs.

Tabela 7 - Desempenho obtido em sistemas semelhantes utilizando um único sensor

<b>Autor</b>	<b>Movimentações reconhecidas</b>	<b>Taxa de acertos</b>
GIACOMOSSI, 2011	Andando, correndo, acenando, batendo palmas e tremores.	81,60%
CHERNBUMROONG e ATKINS, 2011	Sentado, em pé, deitado, caminhando e correndo.	94,13%
YANG e CHO, 2008	Em pé, sentado, caminhando, correndo, aspirando, esfregando, escovando os dentes e trabalhando no computador.	74,40%

Resultados relacionados às taxas gerais de sucesso e às movimentações reconhecidas apresentados em trabalhos similares, e que empregaram um único sensor acoplado ao pulso, são sintetizados na Tabela 7 para comparação de desempenho. Por meio dessa comparação verifica-se que o resultado obtido neste trabalho, envolvendo o reconhecimento de oito movimentações, é altamente

satisfatório, principalmente pelo fato de que quatro das movimentações (andar, correr e subir/descer escadas) corresponderem essencialmente à movimentação dos membros inferiores, ou seja, distantes do local de captura dos sinais (punho). Os trabalhos que utilizaram um número maior de sensores e posicionamentos diferenciados em relação ao deste trabalho não foram utilizados nesta análise comparativa.

Com os resultados apresentados, conclui-se que é eficaz a proposta de oferecer um sistema de baixo custo, composto por um único sensor embarcado em um acessório simples, associado à metodologia desenvolvida para identificação de movimentos básicos da rotina de uma pessoa por meio de técnicas de reconhecimento de padrões. Comparando-se este sistema com outros reportados na literatura, verifica-se que o índice de desempenho no reconhecimento de oito diferentes movimentações está otimizado e com resultados altamente satisfatórios. Para complementar os resultados apresentados, os processos futuros devem elevar o aumento no número de usuários para o aperfeiçoamento do sistema e, avaliar a sua capacidade de generalização em diferentes ambientes.



## Referências

- ACTIGRAPH. Actigraph GT3X+ Monitor: Technical Specifications. Actigraph, Pensacola, 2012. Disponível em: [http://www.theactigraph.com/wpcontent/uploads/ActiGraphGT3X+MonitorSpecs\\_LOW\\_RES.pdf](http://www.theactigraph.com/wpcontent/uploads/ActiGraphGT3X+MonitorSpecs_LOW_RES.pdf). Acesso em 12/08/2012.
- ACTIVINSIGHTS. GeneActiv: Product Brochure. ActivInsights, Kimbolton, 2011. Disponível em: [http://www.geneactiv.co.uk/media/2553/geneactiv\\_6pp\\_148x148\\_004\\_11.pdf](http://www.geneactiv.co.uk/media/2553/geneactiv_6pp_148x148_004_11.pdf). Acesso em 12/08/2012.
- AGGARWAL, J. K.; CAI, Q. **Human Motion Analysis: A Review**. Computer Vision and Image Understanding, v. 73, n. 3, p. 428-440, 1999.
- ANDREJASIC, M. **MEMS ACCELEROMETERS**, seminar. Department of Physics, University of Ljubljana, 2008
- AXELSON, J. **SERIAL PORT COMPLETE: COM Ports, USB Virtual COM Ports, and Ports for Embedded Systems**. 2<sup>nd</sup> ed. Madison: Lakeview Research, 2007. 380p
- BAEK, J.; LEE, G.; PARK, W.; YUN, B. Accelerometer Signal Processing for User Activity Detection. In: **Knowledge-Based Intelligent Information and Engineering Systems.**, p. 610-617.
- BAO, L.; INTILLE, S. Activity recognition from user-annotated acceleration data. **Pervasive Computing**, p. 1-17, 2004.
- BERSCH, S.; CHISLETT, C. M. J.; AZZI, R.; KHUSAINOV, R.; BRIGGS, J. S. Activity detection using frequency analysis and off-the-shelf devices: Fall detection from accelerometer data. In: **Proceedings of The 5th International ICST Conference on Pervasive Computing Technologies for Healthcare. Anais...**: IEEE, 2011.
- BONOMI, A. G. **Physical activity recognition using a wearable accelerometer: New perspectives for energy expenditure assessment and health promotion**. (Doctors thesis) - Universitaire Pers Maastricht, Eindhoven, 2010.
- BROOKE, J. D.; WHITING, H. T. A. Human movement: a field of study. London: Henry Kimpton Publishers, 1973.
- CAMNTECH. MotionWatch 8 and MotionWare User Guide. CamNTech, 2012. Disponível em: <http://www.camntech.com/images/products/MotionWatch/The%20MotionWatch%20User%20Guide.pdf>. Acesso em 12/08/2012
- CHERNBUMROONG, S.; ATKINS, A. S. Activity classification using a single wrist-worn accelerometer. In: 2011 5TH INTERNATIONAL CONFERENCE ON SOFTWARE, KNOWLEDGE INFORMATION, INDUSTRIAL MANAGEMENT AND APPLICATIONS (SKIMA) PROCEEDINGS. **Anais...** Benevento: IEEE, 2011.

- COULOURIS, G.; DOLLIMORE, J.; KINDBERG, T. I. M. **Sistemas Distribuídos: Conceitos e Projeto**. 4<sup>a</sup> ed. Porto Alegre: Bookman, 2007. 784 p.
- CORTES, C.; VAPNIK, V. N. Support-vector networks. *Machine Learning*, 20(3):273–297, 1995.
- DORF, R. C.; BISHOP, R. H. **Sistemas de Controle Modernos**. 8a ed. Rio de Janeiro: LTC, 2001. 684 p.
- DUDA, R. O.; HART, P.E.; STORK, D.G. **Pattern Classification**. 2nd ed. New York: Willey & Sons, 2001. 654p.
- ERMES, M.; PÄRKKÄ, J.; MÄNTYJÄRVI, J.; KORHONEN, I.. Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions. **IEEE transactions on information technology in biomedicine: a publication of the IEEE Engineering in Medicine and Biology Society**, v. 12, n. 1, p. 20-6, 2008.
- FRADEN, J. **Handbook of Modern Sensors: Physics, Designs and Applications**. 3<sup>rd</sup> ed. New York: Springer – Verlag, 2004.
- GAD-EL-HAK. M. **MEMS Design and Fabrication**. 1<sup>st</sup> ed. M. Boca Raton: CRC Press, 2006.
- GIACOMOSSI, L. C. **Método não invasivo utilizando acelerômetro para classificar movimentos normais e anormais de humanos**. 2011. Dissertação (Dissertação de Mestrado). Universidade Tecnológica Federal do Paraná, Curitiba, 2011.
- GODFREY, A.; CONWAY, R.; MEAGHER, D.; ÓLAIGHIN, G. Direct measurement of human movement by accelerometry. **Medical engineering & physics**, v. 30, n. 10, p. 1364-86, 2008.
- GODFREY, A.; BOURKE, A. K.; ÓLAIGHIN, G. M.; VEN, P.; NELSON, J. Activity classification using a single chest mounted tri-axial accelerometer. **Medical engineering & physics**, v. 33, n. 9, p. 1127-35, 2011.
- GYLLENSTEN, C. I. **Physical Activity Recognition in Daily Life using a Triaxial Accelerometer**. Thesis (Masters thesis) - Royal Institute of Technology, Stockholm, 2010.
- HAAPALAINEN, E.; LAURINEN, P.; SIIRTOLA, P.; RÖNING, J.; KINNUNEN, H.; JURVELIN, H. Exercise energy expenditure estimation based on acceleration data using the linear mixed model. In: 2008 IEEE International Conference On Information Reuse And Integration. **Anais...**: IEEE, 2008.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. 2<sup>nd</sup> ed. New York: Springer, 2001
- HAYKIN, S. S. **Redes Neurais: Princípios e Prática**. 2<sup>a</sup> ed. Porto Alegre: Bookman, 2001. 900 p.

- HELMİ, M.; ALMODARRESİ, S. Human activity recognition using a fuzzy inference system. **Fuzzy Systems, 2009. FUZZ-IEEE ...**, p. 1897-1902, 2009.
- JOLLIFFE, I. T. **Discarding Variables in a Principal Component Analysis I: Artificial Data**. Journal of the Royal Statistical Society, Series C (Applied Statistics), 21, 160-173, 1972.
- JOLLIFFE, I. T. **Principal Component Analysis**. 2<sup>nd</sup> ed. New York: Springer, 2002. 489p.
- KAAJAKARI, V. **Practical MEMS: Analysis and design of microsystems, MEMS sensors, electronics, actuators, rf mems, optical mems, and microfluidic systems**. Small Gear Publishing, 2009. 465p
- KARANTONIS, D. M.; NARAYANAN, M. R.; MATHIE, M; LOVELL, N. H.; CELLER, B. G. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. **IEEE transactions on information technology in biomedicine: a publication of the IEEE Engineering in Medicine and Biology Society**, v. 10, n. 1, p. 156-67, 2006.
- KEMPE, V. **Inertial MEMS: Principles and Practice**. 1<sup>st</sup> ed. New York: Cambridge University Press, 2011. 492p.
- KHAN, A. M. **Human Activity Recognition Using A Single Tri-axial Accelerometer Human Activity Recognition Using A Single Tri-axial Accelerometer**. Thesis for Degree of Doctor of Philosophy. Department of Computer Engineering. Seoul: Kyung Hee University, 2011.
- KOHN, A. F. Reconhecimento de padrões: Uma abordagem estatística. Departamento de Engenharia Eletrônica da Escola Politécnica da Universidade de São Paulo, 1998.
- KOSKIMÄKI, H.; HUIKARI, V.; SIIRTOLA, P.; RÖNING, J. Behavior modeling in industrial assembly lines using a wrist-worn inertial measurement unit. **Journal of Ambient Intelligence and Humanized Computing**, 2011.
- KUISMA, H., GILLES, K., ROBERT, D. **3D WLP MEMS: market drivers & technical challenges**. Micronews n<sup>o</sup>76. January 2009.
- LESTER, J.; CHOUDHURY, T.; BORRIELLO, G. A practical approach to recognizing physical activities. **Pervasive Computing**, p. 1-16, 2006.
- LEHTONEN, T.; THURAU, J. Monolithic Accelerometer for 3D Measurements. In: **Advanced Microsystems for Automotive Applications 2004**. Springer Berlin Heidelberg, 2004. p. 11-22, 2004.
- LIM, J.-H.; JANG, H.; JANG, J.; PARK, S. Daily activity recognition system for the elderly using pressure sensors. Conference proceedings: Annual International Conference of the IEEE Engineering in Medicine and Biology Society. **IEEE Engineering in Medicine and Biology Society Conference**, v. 2008, p. 5188 - 5191, 2008.

- LUPRANO, J. On-body diagnosis for wearable systems serving biomedical needs. **Studies in health technology and informatics**, v. 108, p. 162-171, 2004.
- MADOU, M. J. **Fundamentals of Microfabrication**. 1<sup>st</sup> ed. Boca Raton: CRC-Press, 1997. 589p.
- MATHIE, M. **Monitoring and Interpreting Human Movement Patterns Using a Triaxial Accelerometer**. Dissertation for the Degree of Doctor of Philosophy. Sidney: University of New South Wales, 2003.
- MINIMITTER. Actiwatch Actigraph Systems brochure. Mini Mitter, Bend, 2005. Disponível em: <http://www.sitesalive.com/ocl/private/04s/activity/sleep/actiwatch.pdf> . Acesso em 12/08/2012.
- NASA. Actiwatch Fact Sheet. International Space Station Experiments, 2012. Disponível em: [http://www.nasa.gov/mission\\_pages/station/research/experiment\\_s/Actiwatch.html#overview](http://www.nasa.gov/mission_pages/station/research/experiment_s/Actiwatch.html#overview). Acesso em 11/08/2012.
- NEHMER, J., BECKER, M., KARSHMER, A.; LAMM, R. Living assistance systems: an ambient intelligence approach. In ICSE '06: Proceedings of the 28th international conference on Software engineering, pages 43–50, New York, NY, USA. ACM, 2006.
- OPPENHEIM, A. V.; SCHAFER, R. W. **Discrete-Time Signal Processing**. 3<sup>rd</sup> ed. Prentice Hall, 2009.
- PÄRKKÄ, J. **Analysis of Personal Health Monitoring Data for Physical Activity Recognition and Assessment of Energy Expenditure, Mental Load and Stress**. Espoo: Tampere University of Technology. 2011.
- PEKKOLA, J. Modular Inertial Sensing Concepts. VTI Technologies. Presentation. In: **13<sup>th</sup> International Forum on Advanced Microsystems for Automotive Applications**. Berlin, 2009
- PREECE, S. J.; GOULERMAS, J. Y.; KENNEY, L. P. J., HOWARD, D. A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data. **IEEE transactions on bio-medical engineering**, v. 56, n. 3, p. 871-9, 2009.
- PHILIPS. Actiwatch: Product Specifications. Philips Electronics, 2012. Disponível em: [http://www.healthcare.philips.com/pwc\\_hc/main/homehealth/sleep/actiwatch/pdf/ActiwatchTechnicalBrochure.pdf](http://www.healthcare.philips.com/pwc_hc/main/homehealth/sleep/actiwatch/pdf/ActiwatchTechnicalBrochure.pdf) - Acessado em 12/08/2012.
- RASPBERRY PI. FAQ homepage: <http://www.raspberrypi.org/faqs>. Acessado em 06/04/2013.
- RENSHAW, P. **The Nature of Human Movement Studies and Its Relationship with Physical Education**. Quest, Monograph XX, Summer Issue, p.79-86, 1973.

- TI. EZ430-Chronos Development Tool: User's Guide, SLAU292C. Texas Instruments, 2010. Disponível em: <http://www.ti.com/lit/ug/slau292c/slau292c.pdf>. Acesso em 10/07/2012.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4th ed. Academic Press, 2009. 984 p.
- TREW, M.; EVERETT, T. **Human movement**: An introductory text. 4th ed. Edinburgh: Churchill Livingstone, 2001. 292p.
- UGULINO, W.; CARDADOR, D.; VEGA, K.; VELLOSO, E.; MILIDIU, R.; FUKS, H. Wearable Computing: Accelerometers' Data Classification of Body Postures and Movements. **Proceedings of 21st Brazilian Symposium on Artificial Intelligence. Advances in Artificial Intelligence - SBIA 2012**. In: LectureNotes in Computer Science. pp. 52-61. Curitiba, PR: Springer Berlin / Heidelberg, 2012.
- VAPNIK, V. N. An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 10(5):988–999, 1999.
- VTI. CMA3000-D0X Series 3-axis accelerometer: Product Family Specification. VTI Technologies, 2010. Disponível em: [http://www.muratamems.fi/sites/default/files/documents/cma3000-d0x\\_product\\_family\\_specification\\_8281000a.05.pdf](http://www.muratamems.fi/sites/default/files/documents/cma3000-d0x_product_family_specification_8281000a.05.pdf). Acesso em 01/07/2012.
- WANG, J.; CHEN, R.; SUN, X; SHE, M. F., WU Y. Recognizing Human Daily Activities From Accelerometer Signal. **Procedia Engineering**, v. 15, p. 1780-1786, 2011.
- WHO. **Global Recommendations on Physical Activity for Health**. Geneva, 2010.
- YANG, S.-I. e CHO, S.-B. Recognizing human activities from accelerometer and physiological sensors. In: 2008 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems. **Anais...**: IEEE, 2008.
- YANG, C.-C.; HSU, Y.-L. A review of accelerometry-based wearable motion detectors for physical activity monitoring. **Sensors (Basel, Switzerland)**, v. 10, n. 8, p. 7772-88, 2010.
- YANG, J.-Y.; WANG, J.-S.; CHEN, Y.-P. Using acceleration measurements for activity recognition: An effective learning algorithm for constructing neural classifiers. **Pattern Recognition Letters**, v. 29, n. 16, p. 2213-2220, 2008.
- YAMANA, H. **Embedded System for Monitoring Human Activities Using 3-Axis Accelerometer**. Arlington: University of Texas at Arlington, 2007.
- ZHENG, N; XUE, J. **Statistical Learning and Pattern Analysis for Image and Video Processing**. Advances in Computer Vision and Pattern Recognition. Springer, 2009.


## Apêndice A - Acelerômetros

Este capítulo tem como objetivo apresentar de uma maneira geral os sensores acelerômetros, partindo de uma abordagem teórica do dispositivo, na sequência é feita uma apresentação de algumas técnicas de fabricação, seguida pelo princípio de transdução dos acelerômetros mais comuns e por fim é realizada uma abordagem do sensor utilizado neste trabalho: o acelerômetro capacitivo MEMS CMA3000-D1.

### *Princípios básicos*

O acelerômetro é um dispositivo eletromecânico projetado para medir a aceleração de um corpo devido à aplicação de uma força externa. A aplicação dessa força pode resultar em acelerações dinâmicas, como a variação de velocidade em um deslocamento, vibrações e choques, ou aceleração estática, como quando o dispositivo é inclinado e a força de aceleração gravitacional terrestre é projetada sobre os eixos de sensibilidade. Em resumo, este dispositivo converte um vetor de aceleração em um sinal elétrico, que pode ser coletado e processado por sistemas eletrônicos.

Figura 44 - Estrutura básica de um acelerômetro.



Fonte: Autoria própria

A estrutura básica de um acelerômetro (como vista na Figura 44) é constituída por uma massa de prova (também denominada massa sísmica), suspensa por um elemento elástico (mola) e um sistema de amortecimento. Estes componentes são embutidos em um chassi (também chamado de quadro, em inglês *frame*), formando


um sistema dinâmico clássico de 2ª ordem. Essa estrutura é capaz de medir acelerações através da deflexão da massa de prova com a aplicação de uma força externa ao chassi. A estrutura apresentada na Figura 44 permite apenas a medição da aceleração em um único eixo (ou com um grau de liberdade), portanto nos acelerômetros biaxiais e triaxiais, estruturas semelhantes devem ser construídas no sentido dos demais eixos de interesse, fornecendo em sua saída um sinal elétrico correspondente a cada um dos eixos sensíveis.

Analisando as forças envolvidas no modelo de um acelerômetro de deslocamento ao longo do eixo x (como ilustrado na Figura 45), pode-se equacionar:

$$m \frac{\partial^2 x(t)}{\partial t^2} + c \frac{\partial x(t)}{\partial t} + kx(t) = F(t) = ma(t) \quad (\text{A.1})$$

Onde  $m$  é a massa de prova,  $c$  a constante de amortecimento,  $k$  a constante de mola, e  $F$  a força externa.

Figura 45 - Acelerômetro sensível ao eixo x.



Fonte: Kempe, 2011.

A função de transferência que relaciona o deslocamento da massa de prova com a força externa aplicada pode ser obtida aplicando-se a transformada de Laplace, tendo-se:

$$ms^2X(s) + csX(s) + kX(s) = F(s) \quad (\text{A.2})$$


$$\frac{X(s)}{F(s)} = \frac{\frac{1}{m}}{s^2 + \frac{c}{m}s + \frac{k}{m}} \Rightarrow \frac{X(s)}{A(s)} = \frac{1}{s^2 + \frac{c}{m}s + \frac{k}{m}} \quad (\text{A.3})$$

O sistema massa-mola-amortecedor correspondente ao acelerômetro é análogo a um sistema elétrico RLC (Figura 46), que pode ser equacionado da seguinte maneira:

$$r(t) = i_c(t) + i_R(t) + i_L(t) \quad (\text{A.4})$$

$$r(t) = C \frac{\partial v(t)}{\partial t} + \frac{v(t)}{R} + \frac{1}{L} \int_0^t v(t) dt \quad (\text{A.5})$$

Figura 46 - Circuito RLC paralelo.



Fonte: Dorf e Bishop, 2001.

Reescrevendo a equação (A.1) em função da velocidade  $v(t)$  pode-se notar a analogia como exibido a seguir na equação (A.6).

$$M \frac{\partial v(t)}{\partial t} + bv(t) + k \int_0^t v(t) dt = F(t) \quad (\text{A.6})$$

A analogia entre o sistema elétrico e o mecânico é muito útil, pois permite a análise e compreensão do sistema através de outra grandeza física (DORF e BISHOP, 2001), além de possibilitar a simulação do sistema mecânico por um elétrico.

Um acelerômetro também pode ser construído de modo a utilizar a medição da rotação em torno de um eixo para a medição da aceleração, ao invés da medição do deslocamento sobre um eixo. Modificando a geometria da massa de prova, deslocando o seu centro de gravidade e instalando molas torcionais como suporte, é possível determinar o sentido de rotação da massa em reação à aplicação de forças externas em torno do eixo de sustentação.

De uma forma análoga ao equacionamento do acelerômetro de deslocamento sobre o eixo sensível, o arranjo da Figura 47 tem os torques como indicados na equação (A.7).

$$I_y \frac{\partial^2 \theta}{\partial t^2} + c_\theta \frac{\partial \theta}{\partial t} + k_\theta \theta = R_m \cos \theta a_z + R_m \sin \theta a_x - I_y \frac{\partial^2 \theta_s}{\partial t^2} \quad (\text{A.7})$$




Onde  $I_y$  é o momento de inércia da massa em relação ao eixo “y”, que pode ser calculado a partir da equação (A.8).

$$I_y = \int_V \rho (x^2 + z^2) dV \quad (\text{A.8})$$

Sendo  $\rho$  a densidade da massa,  $V$  o volume do corpo,  $R$  a distância entre o eixo “y” e o centro de gravidade,  $R_m \cos \theta a_z$  representa o torque no eixo y provocado pela aceleração  $a_z$ ,  $R_m \cos \theta a_x$  o torque provocado pela aceleração  $a_x$ , e o termo  $I_y \frac{\partial^2 \theta_s}{\partial t^2}$  representa a rotação do substrato.

Figura 47 - Princípio de um sistema massa-mola torcional.



Fonte: Kempe, 2011

Analisando a função de transferência do acelerômetro mecânico na equação (A.3), pode-se calcular a sua frequência natural  $\omega_n$  (frequência de ressonância) e a taxa de amortecimento  $\xi$ , que são os fatores determinantes para estabelecer a largura de banda de trabalho e a sensibilidade mecânica do dispositivo:

$$\omega_n = \sqrt{\frac{k}{m}} \quad (\text{A.9})$$

$$\frac{c}{m} = 2\xi\omega_n \Rightarrow \xi = \frac{c}{2\sqrt{km}} \quad (\text{A.10})$$

A sensibilidade  $S$  do acelerômetro é dada por:

$$S = \frac{1}{\omega_n^2} = \frac{m}{k} \quad (\text{A.11})$$

O fator de amortecimento determina o tempo de resposta e a acomodação do sistema mecânico, afetando a largura de banda de trabalho e a linearidade do sensor (ANDREJASIC, 2008). Analisando os dois parâmetros é possível notar uma

relação de compromisso entre a massa e a constante de mola: uma grande massa de prova permite boa sensibilidade, porém baixa frequência natural, sendo essa uma condição suportada na aplicação de monitoração de movimentações humanas onde não ocorrem oscilações de alta frequência.

### ***Acelerômetros MEMS***

Assim como nos processos de fabricação de circuitos integrados, os acelerômetros MEMS são também fabricados utilizando-se processos de microeletrônica, e com isso um grande número de unidades idênticas podem ser fabricadas ao mesmo tempo em um mesmo substrato, desfrutando das vantagens econômicas deste processo (ANDREJASIC, 2008).

A fabricação das estruturas móveis do sensor acelerômetro é realizada a partir da remoção controlada de material do substrato (silício) ao redor de um ponto alvo. Este ponto alvo pode estar situado em camadas depositadas sobre o substrato (microusinagem de superfície, em inglês *surface micromachining*), ou embutido no próprio substrato (microusinagem de substrato, em inglês *bulk micromachining*) (KEMPE, 2011).

Os processos de microusinagem podem ser compatíveis ou não com os processos convencionais da microeletrônica para a fabricação dos circuitos de aquisição e processamento dos sinais gerados pela transdução no dispositivo. Quando não são compatíveis, o microssistema é composto pela integração de dois elementos separados: a estrutura MEMS e o circuito eletrônico de processamento de sinais (ASIC - *application-specific integrated circuit*).

Os acelerômetros MEMS são comumente projetados para que a transdução ocorra pela exploração de um dos seguintes efeitos físicos: piezoelétrico, piezoresistivo ou capacitivo.

### ***Microusinagem de superfície***

Este processo incorpora características compatíveis com o processo de fabricação de circuitos integrados, onde diversas camadas estruturais e sacrificiais, formadas por filmes finos, são sobrepostas e submetidas a processos de corrosão. Após múltiplas execuções de processos de deposição, corrosão e remoção de material, é possível construir estruturas suspensas e móveis, tais como vigas,

suportes, e molas, que são utilizadas para formar a estrutura básica de um acelerômetro (MADOU, 1997).

As técnicas utilizadas nesse processo são químicas como as deposições químicas de vapor (CVD, *Chemical vapor deposition*), em condições atmosféricas (APCVD) ou em baixa pressão (LPCVD), ou físicas (PVD, *Physical vapor deposition*) como no *sputtering* e na evaporação térmica.


Visto que o processo é compatível com a fabricação simultânea de outros componentes eletrônicos, torna-se possível o desenvolvimento de dispositivos mais integrados, com menores encapsulamentos e conseqüentemente menores custos (KAAJAKARI, 2009). Neste processo, as formas projetadas sobre o plano x-y do dispositivo não estão limitadas à cristalografia do material (GAD-EL-HAK, 2006; MADOU, 1997), permitindo diferentes ângulos e formatos.

Os acelerômetros desenvolvidos com este processo de fabricação utilizam-se dos efeitos capacitivos e de ressonância para efetuar a transdução da aceleração em sinal elétrico (GAD-EL-HAK, 2006).

### ***Microusinagem do substrato***

Este processo envolve a proteção de algumas áreas do substrato e a corrosão (úmida ou seca) da sua estrutura interna para formar as partes móveis do dispositivo.

Figura 48 - Canais abertos por corrosão: a) isotrópica; b) anisotrópica.



Fonte: Gad-el-Hak, 2006.

A corrosão úmida (Figura 48) pode ser anisotrópica, onde o corrosivo oferece diferentes taxas de corrosão de acordo com a direção (orientação cristalográfica), ou isotrópica, onde a taxa de corrosão não depende da orientação cristalográfica do substrato. Neste método de corrosão, a proteção do substrato é feita com a


aplicação de um filme fino e inerte à solução química que irá realizar a corrosão, por exemplo, um filme de óxido de silício para proteção contra TMAH (Hidróxido de tetrametilamônio), ou nitreto de silício contra o KOH (Hidróxido de potássio), ou ainda dióxido de silício contra o HNA.

A corrosão seca utiliza componentes gasosos em um processo puramente químico ou químico-físico. As vantagens deste processo são a menor sensibilidade à variação de temperatura, maior facilidade de interrupção da corrosão, além de não depender da orientação cristalográfica do material, permitindo a fabricação de estruturas menores.

A microusinagem do substrato favorece o uso dos dois lados do substrato, e resulta em dispositivos fabricados com espessura de um, ou múltiplos da espessura de um substrato, e elementos móveis de dimensões e massas maiores se comparadas ao processo de superfície (GAD-EL-HAK, 2006).

Os acelerômetros desenvolvidos com este processo de fabricação utilizam-se dos efeitos capacitivos, piezoelétricos e piezoresistivos para efetuar a transdução da aceleração em sinal elétrico (GAD-EL-HAK, 2006).

Figura 49 - Vistas lateral e superior de arranjos comuns para a suspensão da massa de prova em acelerômetros de substrato microusinado.



Fonte: Gad-el-Hak, 2006.


Uma desvantagem deste processo é a incompatibilidade com a fabricação simultânea de circuitos eletrônicos sobre o mesmo substrato (GAD-EL-HAK, 2006), pois as soluções químicas corrosivas utilizadas para a abertura de canais no substrato também “atacam” partes dos circuitos e contatos de alumínio.

A Figura 49 apresenta alguns exemplos de microusinagem de substrato em arranjos comuns de suspensão de uma massa de prova.

### ***Acelerômetro piezoresistivo***

Como elemento sensível, um acelerômetro piezoresistivo incorpora extensômetros, que medem a tensão nos suportes que estão ligados à massa de prova suspensa. A tensão pode ser diretamente correlacionada com a magnitude e taxa de deslocamento da massa, e subsequentemente com a aceleração (FRADEN, 2004). Os extensômetros utilizam o efeito de variação da resistência elétrica de resistores implantados na estrutura do sensor sob a condição de esforço mecânico (KEMPE, 2011). Em dispositivos de microusinagem de substrato de silício, os piezoresistores podem ser implantados utilizando um processo de dopagem seletiva. O local de implantação dos resistores é cuidadosamente escolhido para obter-se a máxima variação, portanto os resistores são implantados nas juntas das vigas. Um cuidado que deve ser tomado é a compensação da variação da resistência devido à temperatura, pois esta variação pode ser superior à provocada pelo estresse mecânico da estrutura, impedindo a medição de pequenas acelerações.

Figura 50 - Acelerômetro piezoresistivo de 1-dimensão, baseado no conceito viga-massa de prova. (a) Representação gráfica do dispositivo; (b) Vista em corte.



Fonte: Kempe, 2011

Uma forma de medir os pequenos sinais do sensor e simultaneamente compensar a influência da temperatura é implantar resistores formando um circuito ponte de Wheatstone com os quatro resistores variáveis como visto na Figura 50. A tensão de saída na ponte é dada por:

$$V_o = V_i \left( \frac{R + \Delta R}{2R} - \frac{R - \Delta R}{2R} \right) = V_i \frac{\Delta R}{R} \quad (\text{A.12})$$


A variação de temperatura afeta os quatro resistores igualmente, portanto tanto o denominador quanto o numerador sofrem o acréscimo de resistência devido à temperatura, anulando a sua influência na tensão de saída.

### ***Acelerômetro piezoelétrico***

Estes dispositivos baseiam-se no efeito piezoelétrico, que é a geração de cargas elétricas em reação a um esforço mecânico aplicado a um material cristalino. Um acelerômetro piezoelétrico pode ser construído a partir da instalação de eletrodos em uma viga de material cristalino, que por sua vez sustenta a massa de prova do sensor. Quando submetido à aceleração, as oscilações da massa de prova provocarão flexões da viga, que pelo efeito piezoelétrico irão gerar cargas que serão coletadas pelos eletrodos. Uma particularidade deste dispositivo é que ele mede apenas mudanças de aceleração, ou seja, não é capaz de medir a aceleração gravitacional (também chamada de estática) (KAAJAKARI, 2009).

A Figura 51 apresenta um exemplo de acelerômetro piezoelétrico, onde a massa de prova está suspensa por quatro suportes, e nelas estão instalados os eletrodos na posição normal ao sentido da oscilação e o material cerâmico PZT (titanato zirconato de chumbo) responsável pelo efeito piezoelétrico.

Figura 51 - Acelerômetro piezoelétrico com quatro suportes para a massa de prova.



Fonte: Kempe, 2011.

## ***Acelerômetro capacitivo***

A transdução capacitiva é a forma mais simples de estabelecer uma relação entre os circuitos de processamento de sinal e as estruturas móveis de um sensor, além de não sofrerem variações devido à temperatura, diferentemente dos transdutores piezoelétricos e piezoresistivos (KEMPE, 2011).

O conceito básico por trás de qualquer dispositivo capacitivo, independentemente de sua característica construtiva, parte de um capacitor de placas paralelas que tem a sua capacitância dada por:

$$C = \varepsilon \cdot \varepsilon_0 \frac{A}{d} \quad (\text{A.13})$$

Onde:

$\varepsilon_0$  é a permissividade elétrica no vácuo ( $8,854 \times 10^{-12} \frac{F}{m}$ )

$\varepsilon$  é a permissividade relativa do meio entre as placas

$A$  é a área da placa

$d$  é a distância entre as placas.

Variando o eixo de sensibilidade, tecnologia de construção e características de estabilidade e sensibilidade, alguns arranjos comuns são utilizados no projeto da estrutura MEMS de um acelerômetro capacitivo:

- *Capacitor de placas paralelas, contendo um eletrodo fixo e outro móvel:* é geralmente utilizado para medições na direção  $z$  (normal ao plano do substrato), e possui boa restrição de movimento ao eixo de sensibilidade.
- *Capacitor de placas com um eletrodo passível de inclinação:* um eletrodo é fixo e o outro está suspenso por uma mola torcional que permite o movimento de rotação, inclinando a placa. Este arranjo oferece sensibilidade a acelerações nas direções  $x$  ou  $y$  (paralelas ao substrato) e boa restrição de movimentos em direções diferentes da desejada.
- *Capacitor de placas com corpo em formato de pente:* Este arranjo é formado por uma grande estrutura que contém múltiplas placas, dando ao dispositivo a aparência de um pente. A estrutura é dividida em parte fixa, fabricada junto ao substrato, e parte móvel, suspensa sobre o substrato e presa em pontos chamados “âncoras”. Este arranjo oferece sensibilidade a acelerações nas direções  $x$  e  $y$  (paralelas ao substrato), e também na direção  $z$  (normal ao


substrato). Por ser uma estrutura grande, não possui boa restrição a movimentos em outras direções além da desejada.

- *Capacitor de placas com corpo em formato de pente radial*: Este arranjo possui uma estrutura semelhante à descrita no item anterior, tendo como diferença a sua fixação, que é feita por um pivô que permite rotação da estrutura paralela ao plano x-y (plano paralelo ao substrato).

### ***O sensor utilizado neste trabalho***

O acelerômetro utilizado para a captura das movimentações de um indivíduo está inserido dentro de um relógio de pulso (ez430-Chronos da Texas Instruments – cujo circuito eletrônico é ilustrado na Figura 52), que permite a monitoração do usuário sem interferir em suas atividades.

Figura 52 - Placa de circuito do relógio ez430-Chronos.




Fonte: TI, 2010.

O sensor contido no relógio é um acelerômetro capacitivo MEMS, modelo CMA3000-D01, fabricado pela empresa finlandesa VTI Technologies. Por estar embutido em um sistema compacto e sustentado por uma bateria pequena, este sensor atende aos requisitos de baixo consumo de energia, além de possuir dimensão reduzida (2mm x 2mm) e interface de fácil integração a outros circuitos eletrônicos.



Figura 53 - Massa suspensa por uma mola torcional.



Fonte: Lehtonen e Thurau, 2004.


O elemento sensível à aceleração é um composto de três massas de prova, baseando-se no princípio de massas inerciais assimétricas (Figura 53), que pela suspensão por molas torcionais, rotacionam em uma determinada direção pela posição do seu centro de gravidade. As massas compõem o eletrodo central, e nas camadas superior e inferior, eletrodos metálicos são posicionados para formar um circuito capacitivo diferencial em cada uma das massas, totalizando três pares de capacitores. Para ser um dispositivo de medição de pequenas acelerações, da ordem de algumas unidades de  $g$  (onde  $1g = 9,78m/s^2$ ), a massa de prova é projetada para ter alta espessura e massa, aumentando a sensibilidade do sensor.

No que se refere à geometria do sensor, o projeto estabelece que as massas de prova sejam dispostas de maneira tal que as três componentes ortogonais de aceleração podem ser obtidas através de uma combinação linear da medição capacitiva da posição de cada uma das massas.

A estrutura MEMS do sensor é fabricada utilizando um substrato SOI (Silicon on Insulator), permitindo a combinação de processos de microusinagem de substrato e de superfície. Este substrato é composto de três camadas: uma camada inferior (suporte) de silício, geralmente com espessura de  $\pm 500 \mu m$ , uma camada de óxido isolante com espessura de frações de micrometros ( $100 \text{ nm} - 500 \text{ nm}$ ), e uma camada superior de silício com alguns micrometros de espessura (Kempe, 2011). A camada de óxido geralmente é utilizada como camada sacrificial, e no caso deste dispositivo, define com exatidão a espessura da mola torcional (espessura da camada superior). Para o melhor aproveitamento da área de silício, aberturas completamente verticais e formas (no plano x-y) não limitadas à orientação

cristalográfica do material são efetuadas utilizando-se o processo de corrosão seca DRIE (*Deep reactive ion etching*).

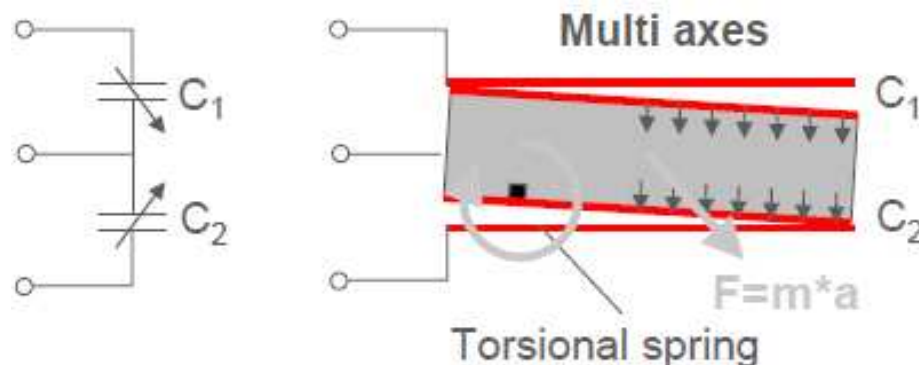
Figura 54 - Camadas do sensor CMA3000.



Fonte: Cortesia da VTI Technologies.

O dispositivo completo envolve a composição de várias camadas (como ilustrado na Figura 54). A camada MEMS, onde está o elemento sensível, é envolvida por duas camadas de proteção (*capping wafers*), sendo que a camada de proteção inferior é ligada a uma camada de distribuição das conexões, que por sua vez permite a conexão do ASIC de aquisição e processamento de sinais utilizando uma técnica onde o chip é montado de forma invertida (*flip-chip bonding*).

Figura 55 - Capacitor diferencial formado pela massa inercial e os eletrodos fixos.




Fonte: Pekkola, 2009.

As camadas de proteção são feitas de vidro e fornecem a isolação e proteção necessárias para a estrutura MEMS sem impedir a movimentação das estruturas móveis (VTI, 2010). Nas superfícies internas dessas camadas, contatos de alumínio são instalados com processos de filmes finos, formando os eletrodos fixos dos conjuntos de capacitores diferenciais (Figura 55). As camadas são anodicamente soldadas, e por fim o ASIC é ligado à camada de conexões onde as esferas


metálicas para conexão externa estão instaladas. Como a estrutura MEMS e o ASIC são produzidos em processos separados, ambos são pré-testados independentemente antes da integração, reduzindo os custos de produção. O dispositivo completo pode ser visto na Figura 56 e uma visão lateral de todas as camadas ligadas é vista na Figura 57.

Figura 56 - Acelerômetro VTI CMA300.



Fonte: VTI, 2010.

Figura 57 - Vista lateral das camadas do acelerômetro CMA3000



Fonte: Kuisma; Gilleo; Robert, 2009.

A Tabela 8 apresenta um resumo das características técnicas do sensor acelerômetro MEMS CMA3000, que será utilizado neste trabalho.

Tabela 8 - Características do sensor CMA3000

---

**Principais características técnicas do acelerômetro CMA3000**

---

- 3 eixos de medição
  - Faixa de trabalho de  $\pm 2$  g ou  $\pm 8$  g
  - Tensão de alimentação de 1,7V a 3,6V
  - Faixa de temperatura de trabalho (Celcius): -40 à 85
  - Sensibilidade de 56 LSB/g
  - Largura de banda do sinal de saída: 80 Hz
  - Tipo de saída: Digital SPI/I2C
  - Dimensão física: 2 x 2 x 0,95 mm<sup>3</sup>
  - Consumo:  $\leq 70 \mu\text{A}$  com taxa de amostragem entre 100 Hz e 400 Hz
-

## Anexo A – Artigo publicado

# Accelerometer Based Intelligent System for Human Movement Recognition

Fernando Ginez da Silva, Elisabete Galeazzo  
 Department of Electronic Systems  
 Escola Politécnica da Universidade de São Paulo  
 Sao Paulo, Brazil  
 fginez@gmail.com, bete@lme.usp.br

*Abstract*—This paper presents the development of a system based on computational intelligence techniques and on an accelerometer to perform, in a comfortable and non-intrusive manner, the recognition of basic movements of a person's routine. The information provided by this system can be directed to support promoting health and well-being of the individual, as well as diagnosing and remote patient monitoring. The system provides an overall success rate in recognition of movements around 93% by using support vector machines for signal classification and Fisher's discriminant ratio to select the most significant features.

*Keywords*—Accelerometer; Movement classification; Wearable sensor; Computational intelligence; Ambient assisted living.

### I. INTRODUCTION

Contemporary society has experienced an intense degradation of health conditions due to the unhealthy habits introduced by modern lifestyle in urban environments, which expands in an unplanned and very fast way, as well as to the culture and economic transformations resulting from globalization [1], among others factors. One of these habits is sedentary lifestyle, which results in the emergence of non-communicable diseases (NCDs), such as venous and cardiovascular diseases, diabetes, hypertension, some types of cancer, besides obesity, which, in turn, causes other health problems. In 2007, NCDs were responsible for 72% of the total deaths in Brazil [2]. In addition to this context of physical inactivity, the population aging (caused by the increase of life expectancy) should be considered, besides the shortage of financial resources for public health. These facts are motivators for the development of researches and new technologies which facilitate the execution of health policies and promote well-being for the population.

With the recent technological advances in acceleration sensors, microprocessors and wireless communication areas, ubiquitous systems, especially wearable systems [3], are becoming interesting ways for helping professionals in the health area. These advances make possible the quantification or evaluation of the level and the type of physical activity of an individual [4], allowing monitoring the sedentary lifestyle occurrence; remote monitoring patients or elderly people in their home environment, as part of an AAL (Ambient Assisted Living) [5]; and the acquisition of information which can be

correlated to other medical diagnosis data, such as the recognition of movements during the Holter ECG [6], avoiding the manual register of physical activities.

A wide variety of studies in the HAR (Human Activities Recognition) area is reported in the literature, which use accelerometer sensors to identify the movements and suggest the chest or the waist as preferential locations for its installation, resulting in high performance indexes (97% in [7] and 97.5% in [8]); in multisensory approaches, the preferential locations for sensors installation also include the body extremities (wrists and ankles) (with performance indexes of 89% in [4], 90% in [9] and 99.4% in [10]). Despite the excellent results presented, these studies have excluded or minimized aspects such as comfort or even users' difficulty in installing the devices in the body without external assistance.

Within this context, our purpose is to present the results of the development of a non-invasive and low-cost system to capture signals related to daily movements, which is composed by a software of movement recognition and by a hardware based on a single accelerometer sensor attached to the individual's wrist, considering the great comfort offered by this location and the ease of installing it, without the need of professional help. In order to offer a complete solution, a simple, portable and low-cost embedded system will be presented, which is able to receive information about the movements and make them available in a local network for being monitored by a professional of the health area.

### II. MATERIALS AND METHODS

In the system developed, the movements performed by an individual are monitored by the accelerometer attached to the wrist and the signals processing is performed in a remote way (externally to the watch, as illustrated in diagram of Fig. 1) by a system developed in MATLAB. This way, the acceleration signals collected by the device are sent, through a RF link, to a personal server. The samples are stored and processed in this server for automatically recognizing the movements using a classification algorithm (pattern recognition).

The signal acquisition system is based on the ez430-Chronos development platform, from Texas Instruments (approx. cost: US\$49), composed of a watch and a transceiver with USB interface, which allows the constant communication

with a remote computer. Both devices are based on 16-bit MSP430 microcontrollers (CC430F6137), which contain a RF chip operating in sub-1 GHz frequency bands (433 MHz in this system) [11]. The sports watch (illustrated in Fig. 2) integrates a capacitive accelerometer MEMS tri-axial, with  $\pm 2g$  sensitivity, besides temperature and pressure sensors.

It must be emphasized that the system developed, which is based on a sports watch, has advantages for example, the ease of fixing the sensor to the wrist, which avoids the occurrence of displacements of this device in the body during monitored movements and, consequently, facilitates recognition, besides the comfort, allowing monitoring for long hours, since the use of a watch is unnoticed, in contrast to a sensor attached to a strap on the chest, or when many sensors are used.

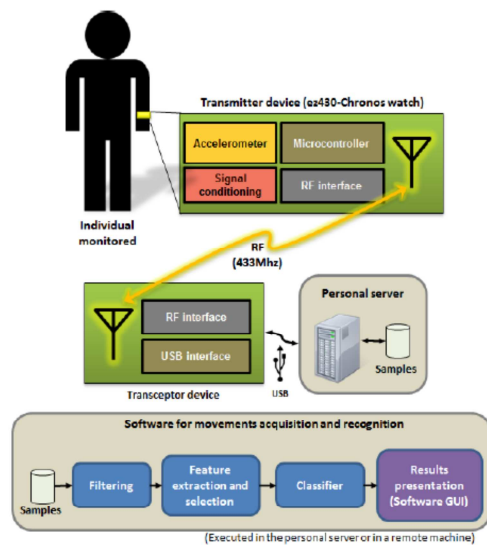


Fig. 1. Diagram of the acquisition and recognition system




Fig. 2. ez430-Chronos (a) Watch and its transceptor; (b) Sensor axes.

#### A. Sample acquisition and segmentation

The accelerometer embedded in the watch does the sampling of the signals with a sample rate of 33 Hz, which is compatible with the frequency band verified in the human movements [7]. The signals collected are segmented in windows with 128 samples (totaling an interval of 3.88 s per window), since "128" can be represented by a power of base 2, increasing the efficiency of the mathematical operations. Each window contains an overlap of 50%, i.e., each window has half

of the samples of the previous window, preventing movements located in the junction between two segments from failing to be computed.

#### B. Procedures for the Sampling of Movements

As the proposal of the system is based on a single accelerometer attached to the wrist of an individual, only some basic movements were selected for the autonomous recognition (listed in Table I).

TABLE I. MOVEMENTS RECOGNIZED BY THE SYSTEM

Recognized movements			
1	Lying	5	Running
2	Sitting	6	Climbing stairs
3	Standing	7	Coming down stairs
4	Walking	8	Working on computer

For the forming of the data base for supervised training and posterior constitution of the classifier, 6 individuals using the ez430-Chronos watch were invited to execute, in their home environment, sequences of previously planned movements which resulted in 157696 samples of the signals, segmented into 2464 windows. In order to avoid manually entering the beginning and the end of each movement, which could result in mistakes and inaccuracies, the routines of acquisition, reception and storage of signals as well as a graphic interface of assistance were integrated into a single software developed in .NET C#.

#### C. Pre-Processing

In this system, all the acceleration signals are submitted to a digital filtering step soon after its acquisition and reception. The first step of this processing corresponds to a moving average low-pass filter with 3 coefficients, which aims at blocking the presence of high frequency noises and minimizing the effects of random errors which occur during the sampling process. Then, the filtered signals are submitted to a second filter, high-pass type, with a cut-off frequency of 0.5 Hz, to eliminate the gravitational acceleration (which corresponds to the DC component). Just then, the resulting signal (containing only the body acceleration) is used together with a pre-classifier to determine if it matches a posture (standing, sitting, lying or working on computer) or to a movement (walking, running, climbing or going down stairs).

#### D. Feature extraction and selection

So as to reduce the dimensionality of the sample windows, and to facilitate the identification of each movement, some features are extracted from the acceleration signals, and these are obtained in the time domain (presented in Table II) and also in the frequency domain (Table III).

In time domain, features are directly extracted from the sample windows, and the calculation is done for each of the three axes of the sensor ( $x[n]$ ,  $y[n]$  and  $z[n]$ ). With respect to frequency domain, the sample windows are firstly submitted to a Discrete Fourier Transform (DFT), and then they are extracted from the signals (in frequency) related to each axis

( $X[k]$ ,  $Y[k]$  e  $Z[k]$ ). After the extraction, each feature is normalized in order to have null mean and unitary variance.

By searching for parameters, which result in the best configuration of each classification algorithm (to be detailed further), the most significant features were automatically selected by the FDR (Fisher's Discriminant Ratio) or PCA (Principal Component Analysis) techniques, so as to evaluate its influence on the final performance of the classifier. From the total of 31 extracted features, 19 were selected by the FDR criterion and 21 by PCA.

#### E. Movements recognition

Three different computational intelligence techniques were evaluated in order to search for the best performance of the recognition of the movements executed by the watch user. The Multilayer Perceptron (MLP) Artificial Neural Networks [12], the k-Nearest Neighbors technique (kNN) [13], and the Support Vector Machines (SVMs) [13] were chosen for this purpose due to the good performance presented previously for signals related to the human movement [4, 7, 8, 9, 14, 15, 16]. Each technique was evaluated in two different classification architectures: in the first, a single classifier was used to identify all the movements without the use of the pre-classifier and without the signal resulting from the high-pass filter; in the second, a pre-classifier based on thresholds of the features "Signal Magnitude Area" and "Average Energy" was used to separate the samples into "movements" or "postures", directing them to dedicated classifiers. The functional diagram of these two architectures is illustrated in Fig. 3.

In addition to the use of different algorithms and classification architectures, the evaluation of performance also involved the permutation of parameter values related to each technique of computational intelligence, i.e., the neural networks changed in the number of hidden layers (one or two)

and in the number of neurons per layer (from 10 to 30), the kNN classifiers changed in the number of "k" neighbors (from 1 to 10), and finally, the SVMs changed the  $c$  (from  $2^{-5}$  to  $2^{15}$ ) and gamma ( $2^{-5}$  to  $2^3$ ) parameters of the RBF (Radial basis function) kernel used in its construction.

Finally, in order to obtain a more reliable measure of the performance of each classifier configuration, and mainly about its generalization capability, the cross-validation technique "k-fold" with  $k=5$  was applied. In this way, for each configuration, the data was split into five folds of the same size and mutually exclusive and, at each trial, four were used for training and one for testing. After the execution of the five trials alternating the folds, the general performance was calculated by an average of the individual performances after 10 evaluation rounds.

#### F. System integration proposal

Keeping the focus on the development of a simple, portable and low cost system, an embedded system (illustrated in Fig. 4) was applied as an alternative to the personal server used for the sample reception and storage.

This embedded system, which must be present in the monitored individual's environment, is formed by a microcomputer (in the approximate size of a credit card) based on Raspberry Pi platform (approx. cost: US\$35) [17], where the watch transceiver, a 3G modem for internet access, the cable of the local area network (LAN), a memory card with Linux operating system, and also a battery are connected. By using this embedded system as a personal server, the samples can be received and sent for processing in a computer of the same local network, or through the internet to any other computer. In a more advanced approach, the processing could also be executed locally, since there is a good processing capability available and an entire software infrastructure for the execution of mathematical libraries and pattern recognition (i.e. libSVM [18]) over the Linux operating system.

TABLE II. TIME DOMAIN FEATURES

Mean	Signal Magnitude Area	Standard Deviation	Skewness
$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$	$SMA(x, y, z) = \sum_{i=1}^N ( x_i  +  y_i  +  z_i )$	$\sigma_{dp} = \sqrt{\frac{1}{(N-1)} \sum_{i=1}^N (x_i - \bar{x})^2}$	$s(x) = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^{3/2}}$
Kurtosis	Correlation	Variation	Unchanged Samples
$k(x) = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^2}$	$\rho(x, y) = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}}$	$\text{var}(x) = \max_i(x_i) - \min_i(x_i)$	"Maximum consecutive unchanged samples quantity"

TABLE III. FREQUENCY DOMAIN FEATURES

Mean Energy	Entropy	Maximum Magnitude and Frequency
$E(k) = \sum_{k=m}^n X(k)$	$H(x) = -\sum_{k=1}^N X(k) \log(X(k))$	$M(k) = \max_i( X(k_i) )$

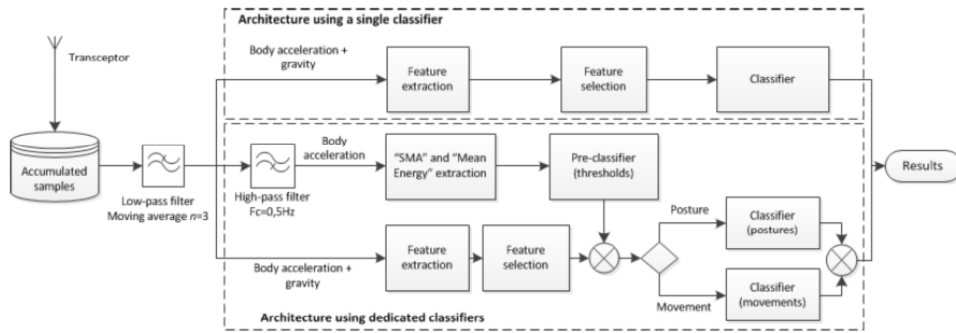


Fig. 3. Architectures applied to the movement recognition




Fig. 4. Embedded system used as a personal server

III. RESULTS AND DISCUSSION

As described in the materials and methods section, the two architectures of classification were evaluated by the use of MLP artificial neural networks, kNN and SVM techniques for pattern recognition, and by using FDR or PCA for feature selection.

TABLE IV. PERFORMANCE COMPARISON AMONG THE CLASSIFIERS.

Configuration		MLP	kNN	SVM
Architecture 1	FDR	90.14%	91.10%	93.47%
	PCA	90.91%	84.01%	91.03%
Architecture 2	FDR	87.34%	88.20%	90.63%
	PCA	87.91%	80.15%	88.76%

TABLE V. CONFUSION MATRIX FOR THE BEST CLASSIFIER.

		Real class								Success rate
		1	2	3	4	5	6	7	8	
Predicted class	1	304	3	1	1	0	0	0	9	96.20%
	2	1	385	0	2	0	0	0	16	93.22%
	3	1	0	325	1	1	0	0	0	97.31%
	4	2	2	3	298	0	18	9	2	88.96%
	5	1	1	1	4	219	0	0	0	99.55%
	6	0	0	2	20	0	214	9	0	88.07%
	7	1	0	2	9	0	11	216	0	92.31%
	8	6	22	0	0	0	0	0	342	92.68%

Table IV presents the best results from the implementation and evaluation of each architecture proposals, feature selection technique and algorithm for classification. From these results, it can be noticed that the best performance was obtained with the single classifier architecture, based on a SVM and feature selection by FDR, with kernel parameters being  $c=2^{-1}$  and  $\gamma=2^{-3}$ , resulting in a success general rate of 93.47%, and individual performances above 88%, as shown in Table V.

Analyzing the general performance of the two architectures among the different techniques, it is noticed that the architecture using a single classifier presents a slightly higher performance, and this small difference is mainly due to the fact that the pre-classifier has a small error rate, among others aspects.

As a result of the comparative analysis, the classifier with the best performance was adopted as the most suitable, being used for composing the movement recognition software, whose GUI (Graphical User Interface) is presented in Fig. 5. This software allows professionals of the area to follow the movements performed by the watch user in real time. The current implementation allows just the reception of the samples (sent by the personal server) by means of the Ethernet interface, and performs the steps of processing and movement recognition locally (in the supervisor's computer), using the methodology described here in.

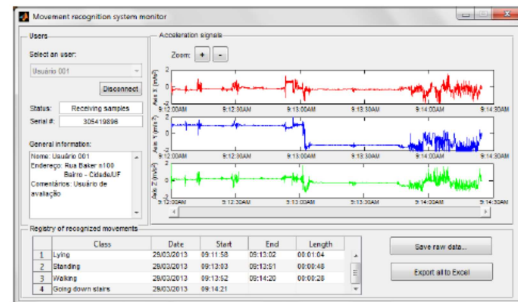


Fig. 5. Graphical user interface of the movement recognition software.



Results related to the general success rates and to the recognized movements presented in similar works, which have used a single sensor attached to the wrist, are synthesized in Table VI for performance comparison. This comparison allowed evaluating the quality of the results from this work, involving the recognition of 8 movements, which is highly satisfactory, mainly because four of the movements analyzed (walking, running and climbing/going down stairs) essentially involved the movement of the lower limbs, far from the signal capturing place (wrist). The works using a larger number of sensors and differentiated positioning in relation to this work were not used in this comparative analysis.

TABLE VI. PERFORMANCE REACHED BY OTHER AUTHORS IN SIMILAR WORKS

Author	Movements	Success
[14]*	Walking, running, waving, clapping and tremors.	81.60%
[15]	Sitting, standing, lying, walking and running.	94.13%
[16]	Standing, sitting, walking, running, vacuuming, rubbing, tooth brushing and working on computer.	74.40%

\*The experiment involving more than a single user was considered.

Finally, some battery life tests were carried out resulting in of approximately 4 days autonomy for the watch (with continuous communication) and 11h (after AC power failure) for the embedded system. These results are acceptable for this proof of concept, but mainly the watch battery life should be increased.

#### IV. CONCLUSION

This work showed that the recognition of basic human movements through a single MEMS triaxial accelerometer embedded in a wrist watch is possible, offering a solution which can be used in monitoring for long periods, being highly attractive, for example, in an Ambient Assisted Living (AAL).

Among the techniques analyzed for pattern recognition, the Support Vector Machines (SVMs), allied with the selected data by the FDR technique, presented the best performance, reaching 93.47% of success into the recognition.

With the results presented, it is possible to conclude that the proposal for developing a low-cost system, composed by a single sensor embedded in a simple accessory, associated to the methodology developed for identifying basic movements of a person's routine by means of pattern recognition techniques, proved effective. Comparing this system with others reported in the literature, it is verified that the performance in the recognition of eight different movements is optimized, with highly satisfactory results. However, to complement the results presented, the future processes must involve the increase of the number of users for the improvement of the system and the evaluation of the capacity for generalization in different environments.

The future steps of this work may also include the battery life increase, evolution of the monitoring software, in order to allow receiving samples through the internet, as well as a more advanced version, in which the whole processing and recognition will be performed in the embedded system presented in this work.

#### REFERENCES

- [1] World Health Organization. "Global status report on noncommunicable diseases 2010," WHO, Geneva, 2011.
- [2] Ministério da Saúde. "Vigitel Brasil 2011: vigilância de fatores de risco e proteção para doenças crônicas por inquérito telefônico." Secretaria de Vigilância em Saúde, Secretaria de Gestão Estratégica e Participativa, Brasília, 2012.
- [3] G. Coulouris, J. Dollimore, and T. Kindberg. *Sistemas distribuídos: conceitos e projeto*, 4<sup>ª</sup> ed. Porto Alegre: Bookman, 2007.
- [4] J. Parkkã, "Analysis of personal health monitoring data for physical activity recognition and assessment of energy expenditure, mental load and stress," Espoo: Tampere University of Technology, 2011.
- [5] J. Nehmer, M. Becker, A. Karshmer, and R. Lamm, "Living assistance systems: an ambient intelligence approach," in Proc. 28th Int. Conf on Softw. Eng., Shanghai, China, May 20-28, 2006, pp. 43-50.
- [6] M. Wetzler, J. R. Borderies, O. Bigaignon, P. Guillo, and P. Gosse, "Validation of a two-axis accelerometer for monitoring patient activity during blood pressure or ECG holter monitoring," *Clinical and Pathological Studies*, 2003.
- [7] M. Mathie, "Monitoring and interpreting human movement patterns using a triaxial accelerometer," Ph.D. thesis, University of New South Wales, Sydney, 2003.
- [8] J. Baek, G. Lee, W. Park, and B. Yun, "Accelerometer signal processing for user activity detection," *Proc. Knowl-Based Intell. Inf. Eng. Syst.*, 2004, pp. 610-617.
- [9] M. Ermes, J. Parkka, J. Mantyjarvi and I. Korhonen, "Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions," *IEEE Trans. Inf. Technol. Biomed.*, vol. 12, 2008, pp. 20-26.
- [10] W. Ugulino, D. Cardador, K. Veg. E. Velloso, R. Milidiu, and H. Fuks, "Wearable Computing: Accelerometers' Data Classification of Body Postures and Movements," in Proc. of the 21<sup>st</sup> Brazilian Symposium on Artificial Intelligence, Curitiba, Brazil, 2012, pp. 52-61.
- [11] Texas Instruments, "EZ430-Chronos Development Tool: User's Guide," <http://www.ti.com/tool/ez430-chronos/> Accessed in 04/06/2013.
- [12] S. S. Haykin, *Redes neurais: princípios e prática*. 2<sup>ª</sup> ed. Porto Alegre: Bookman, 2001.
- [13] S. Theodoridis, and K. Koutroumbas, *Pattern Recognition*. 4th ed. San Diego: Academic Press, 2008.
- [14] L. C. Giacomossi, "Método não invasivo utilizando acelerômetro para classificar movimentos normais e anormais de humanos," *Dissertação de Mestrado*, Univ. Tec. Federal do Paraná, Curitiba, 2011.
- [15] S. Chembumroong, A. S. Atkins, and Yu Hongnian, "Activity classification using a single wrist-worn accelerometer," in Proc. of the 5th International Conference on Software, Knowledge Information, Industrial Management and Applications (SKIMA), Benevento, 2011, pp. 1-6.
- [16] S.-I. Yang, and S.-B. Cho, "Recognizing Human Activities from Accelerometer and Physiological Sensors," in Proc. of the IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, Seoul, Korea, August 20-22, 2008, pp. 100-205.
- [17] Raspberry Pi, "FAQ homepage," <http://www.raspberrypi.org/faqs> Accessed in 04/06/2013.
- [18] LibSVM, "libSVM: A library for Support Vector Machines," <http://www.csie.ntu.edu.tw/~cjlin/libsvm/> Accessed in 04/06/2013.