

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

YVES LUDUVICO COELHO

**DESENVOLVIMENTO DE UM SISTEMA DE RECONHECIMENTO DE
ATIVIDADES HUMANAS E MONITORAMENTO REMOTO UTILIZANDO UM
DISPOSITIVO VESTÍVEL**

VITÓRIA
2017

YVES LUDUVICO COELHO

**DESENVOLVIMENTO DE UM SISTEMA DE RECONHECIMENTO DE
ATIVIDADES HUMANAS E MONITORAMENTO REMOTO UTILIZANDO UM
DISPOSITIVO VESTÍVEL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Teodiano Freire Bastos Filho

VITÓRIA
2017

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial Tecnológica,
Universidade Federal do Espírito Santo, ES, Brasil)

C672d Coelho, Yves Luduvico, 1989-
Desenvolvimento de um sistema de reconhecimento de
atividades humanas e monitoramento remoto utilizando um
dispositivo vestível / Yves Luduvico Coelho. – 2017.
145 f. il.

Orientador: Teodiano Freire Bastos Filho.
Dissertação (Mestrado em Engenharia Elétrica) –
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Sistemas embarcados (Computadores). 2. Sensoriamento
remoto. 3. Reconhecimento de padrões. 4. Reconhecimento de
atividades humanas. 5. Dispositivos vestíveis. I. Bastos Filho,
Teodiano Freire. II. Universidade Federal do Espírito Santo.
Centro Tecnológico. III. Título.

CDU: 621.3

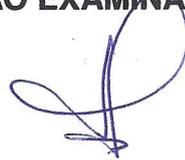
YVES LUDUVICO COELHO

**DESENVOLVIMENTO DE UM SISTEMA DE RECONHECIMENTO DE
ATIVIDADES HUMANAS E MONITORAMENTO REMOTO UTILIZANDO UM
DISPOSITIVO VESTÍVEL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Aprovado em 17 de março de 2017.

COMISSÃO EXAMINADORA



Prof. Dr. Teodiano Freire Bastos Filho
Universidade Federal do Espírito Santo
Orientador



Prof. Dr. Anselmo Frizera Neto
Universidade Federal do Espírito Santo
Examinador interno



Prof. Dr. Luciano Silva
Universidade Federal do Paraná
Examinador externo

À minha família.

AGRADECIMENTOS

À minha família, pelo apoio e incentivo imprescindíveis para a realização desta pesquisa.

Ao meu orientador Teodiano Freire Bastos Filho, pelas contribuições indispensáveis e pelo empenho dedicado à elaboração deste trabalho.

Aos meus companheiros do Núcleo de Tecnologia Assistiva da UFES, pelas contribuições e participações nos testes realizados nesta pesquisa.

Aos colegas de trabalho do i9lab, pelas importantes sugestões para o desenvolvimento deste trabalho.

A todos os professores do Programa de Pós-Graduação em Engenharia Elétrica, que foram importantes na minha vida acadêmica e no desenvolvimento desta dissertação.

Ao Programa de Pós-Graduação em Engenharia Elétrica e à Universidade Federal do Espírito Santo pela estrutura oferecida de laboratórios, equipamentos e ferramentas, essencial para produção desta pesquisa.

RESUMO

Fatores como o envelhecimento da população e o conseqüente aumento do número de pessoas com doenças crônicas implicam um crescimento exponencial dos custos de assistência médica, visto que o sistema de saúde deve ser capaz de atender a um número cada vez maior de pessoas, mantendo a qualidade do atendimento. Visando redução de custos e melhoria da qualidade, seria desejável um sistema de saúde focado no paciente, no qual se poderia detectar precocemente condições médicas, evitando hospitalizações, bem como acompanhá-los remotamente, evitando a permanência destes no hospital. Nesse contexto, dispositivos de monitoramento remoto tornam-se essenciais para coletar informações importantes de pacientes e torná-las disponíveis ao provedor de saúde. O avanço tecnológico conseguido com a miniaturização de sensores e as novas tecnologias de comunicação sem fio de baixo consumo energético impulsionam o desenvolvimento de sistemas de monitoramento remoto de saúde com dispositivos vestíveis. O presente trabalho propõe o desenvolvimento de um sistema de reconhecimento de atividades humanas e de monitoramento remoto, utilizando três diferentes abordagens. Para a primeira abordagem, conseguiu-se uma acurácia de 89,11% e precisão de 91,45% na classificação de seis diferentes atividades. Já para as duas últimas abordagens, construiu-se a estrutura completa de monitoramento remoto da intensidade das atividades realizadas por uma pessoa, desde a coleta dos dados até o envio por e-mail para acompanhamento à distância pelo provedor de saúde. Os resultados obtidos com o sistema desenvolvido demonstram a sua viabilidade tanto para o reconhecimento de atividades humanas quanto para monitoramento remoto.

Palavras-chave: Sistemas Embarcados, Dispositivos Vestíveis, Reconhecimento de Padrões, Reconhecimento de Atividades Humanas, Monitoramento Remoto.

ABSTRACT

Factors such as the aging population and the consequent increase in the number of people with chronic diseases lead to an exponential increase of healthcare costs, since the healthcare system must be able to serve an increasing number of people while maintaining the quality of the attendance. In order to reduce costs and improve quality, it is important to move towards a patient-centered healthcare system, in which it is possible to detect early warning signs, avoiding hospitalizations, as well as follow the patients remotely, avoiding a stay in the hospital. In this context, remote monitoring devices become essential for gathering of important patient information and for making them available to the healthcare provider. The technological advancement regarding the miniaturization of sensors and the new low-power wireless communication technologies encourage the development of remote health monitoring systems. This work proposes the development of a system of human activity recognition and remote monitoring in three different approaches. For the first approach, an accuracy of 89.11% and a precision of 91.45% were obtained when classifying six different activities. For the last two approaches, a complete structure of remote monitoring was developed to monitor the user's activity intensity, from the data collection, in order to transfer it by e-mail to the health provider. Results demonstrate the efficacy of this system for human activity recognition and remote monitoring.

Keywords: Embedded Systems, Wearable Devices, Pattern Recognition, Human Activity Recognition, Remote Monitoring.

LISTA DE SIGLAS

ANN	<i>Artificial Neural Networks</i>
BLE	<i>Bluetooth Low Energy</i>
BR	<i>Basic Rate</i>
BSN	<i>Body Sensor Network</i>
ECG	Eletrocardiograma
EDR	<i>Enhanced Data Rate</i>
GSM	<i>Global System for Mobile Communications</i>
GPRS	<i>General Packet Radio Service</i>
HAR	<i>Human Activity Recognition</i>
HMM	<i>Hidden Markov Model</i>
IoT	<i>Internet of Things</i>
LDA	<i>Linear Discriminant Analysis</i>
NTA	Núcleo de Tecnologia Assistiva
NFC	<i>Near Field Communication</i>
PCA	<i>Principal Component Analysis</i>
PDA	<i>Personal Digital Assistant</i>
RFID	<i>Radio-Frequency Identification</i>
SBE	<i>Sequential Backward Elimination</i>
SPI	<i>Serial Peripheral Interface</i>
SMA	<i>Signal Magnitude Area</i>
SVM	<i>Support Vector Machine</i>
TIC	Tecnologia de Informação e Comunicação
UART	<i>Universal Asynchronous Receiver/Transmitter</i>

USART *Universal Synchronous/Asynchronous Receiver/Transmitter*

UFES Universidade Federal do Espírito Santo

LISTA DE TABELAS

Tabela 1 - Características dos dados por categoria.....	42
Tabela 2 - Abordagens do sistema desenvolvido.....	54
Tabela 3 - Desvio percentual dos atributos entre as atividades.....	80
Tabela 4 – Saídas da rede MLP e as atividades associadas.....	86
Tabela 5 - Distribuição de amostras coletadas.....	95
Tabela 6 - Divisão das partições por rodadas de teste.....	102
Tabela 7 - Acurácia da rede MLP para diferentes topologias da rede.....	103
Tabela 8 - Acurácia da rede MLP por taxa de aprendizagem.....	104
Tabela 9 - Acurácia da rede MLP por precisão.....	104
Tabela 10 - Desempenho da rede MLP.....	105
Tabela 11 - Matriz de confusão da rede MLP.....	105
Tabela 12 - Desempenho da rede MLP com seleção de atributos.....	106
Tabela 13 - Matriz de confusão da rede MLP com seleção de atributos.....	107
Tabela 14 - Desempenho da Hierarquia de Perceptrons.....	109
Tabela 15 - Matriz de confusão da Hierarquia de Perceptrons.....	109
Tabela 16 - Desempenho dos classificadores.....	110
Tabela 17 - Desempenho dos classificadores com seleção de atributos.....	111
Tabela 18 - Desempenho dos classificadores.....	112
Tabela 19 - Desempenho do classificador embarcado no dispositivo.....	113
Tabela 20 - Matriz de confusão do participante S4.....	114
Tabela 21 - Matriz de confusão dispensando o participante S4.....	115
Tabela 22- Comparação com outros trabalhos.....	116
Tabela 23 - Desempenho do algoritmo contador de passos.....	121

Tabela 24 - Matriz de confusão média dos testes.....	143
Tabela 25 - Matriz de confusão do participante S ₁	143
Tabela 26 - Matriz de confusão do participante S ₂	144
Tabela 27 - Matriz de confusão do participante S ₃	144

LISTA DE FIGURAS

Figura 1 - Exemplos de dispositivos vestíveis.	26
Figura 2 - Estrutura genérica de um sistema vestível.	27
Figura 3 - Pilha do protocolo Bluetooth.	33
Figura 4 - Exemplos de módulos BLE.	34
Figura 5 - Diagrama geral do sistema desenvolvido.	53
Figura 6 - Funcionamento da abordagem A ₁	56
Figura 7 - Funcionamento da abordagem A ₂	57
Figura 8 - Funcionamento da abordagem A ₃	58
Figura 9 - Diagrama do <i>hardware</i> do dispositivo vestível desenvolvido.	59
Figura 10 - Esquemático do circuito de alimentação e de proteção.	60
Figura 11 - Desenho do microcontrolador ATmega328p.....	61
Figura 12 - Esquemático do microcontrolador.....	62
Figura 13 - Desenho e dimensões do acelerômetro ADXL362.	63
Figura 14 - Esquemático do acelerômetro.	63
Figura 15 - Módulo HM-10 e dimensões.	64
Figura 16 - Esquemático do módulo BLE.	64
Figura 17 – <i>Layout</i> da PCI: a) camada superior; b) camada inferior.	65
Figura 18 - PCI produzida: a) camada superior; b) camada inferior.	65
Figura 19 - Partes do protótipo desenvolvido.	66
Figura 20 - Protótipo montado e suas dimensões.	66
Figura 21 - Dispositivo vestível: a) como um cinto; b) como uma pulseira.	67
Figura 22 - Código de configuração dos <i>firmwares</i>	68
Figura 23 - Algoritmo do sistema de HAR.	69

Figura 24 - Algoritmo responsável pelo cálculo e pelo armazenamento do desvio padrão da aceleração.....	70
Figura 25 - Algoritmo contador de passos.....	71
Figura 26 - Tela inicial do aplicativo móvel.....	72
Figura 27 - Tela de operação do aplicativo móvel da abordagem A ₁	73
Figura 28 - Aplicativo móvel da abordagem A ₂ : a) tela de operação; b) confirmação de envio de dados por e-mail.	74
Figura 29 - Tela de operação do aplicativo móvel da abordagem A ₃	75
Figura 30 - Aplicação para visualização dos dados coletados.	76
Figura 31 – Orientação do acelerômetro em relação ao corpo do indivíduo.	78
Figura 32 - Exemplo de dados de aceleração coletados.....	80
Figura 33 - Exemplo da segmentação dos dados.	82
Figura 34 - Classificador hierárquico baseado em Perceptrons.	88
Figura 35 - Fluxograma do contador de passos.....	91
Figura 36 - Aceleração no eixo Y durante caminhada e destaques.	91
Figura 37 - Aceleração nos eixos Y e Z das atividades: a) sentado; b) em pé.....	95
Figura 38 - Aceleração nos eixos Y e Z das atividades: a) andando; b) correndo. ...	96
Figura 39 - Aceleração nos eixos Y e Z das atividades: a) subindo escadas; b) descendo escadas.	96
Figura 40 – Comparação gráfica entre as atividades estáticas e dinâmicas.....	97
Figura 41 – Comparação gráfica entre as atividades “sentado” e “em pé”.....	98
Figura 42 - Comparação gráfica entre a atividade "correndo" e as outras atividades dinâmicas.	99
Figura 43 - Comparação gráfica entre as atividades "andando", "subindo escadas" e "descendo escadas", em relação às médias da aceleração nos eixos Y e Z.	100

Figura 44 - Comparação gráfica entre as atividades dinâmicas "andando", "subindo escadas" e "descendo escadas", em relação ao desvio padrão da aceleração nos eixos Y e Z.	100
Figura 45 - Comparação gráfica entre as atividades "andando", "subindo escadas" e "descendo escadas", em relação à mediana da aceleração no eixo Z e da SMA da aceleração no eixo Y.	101
Figura 46 - Comparação gráfica entre as atividades "andando", "subindo escadas" e "descendo escadas", em relação à mediana da aceleração no eixo Y e da faixa do sinal da aceleração no eixo Z.	101
Figura 47 - Dados coletados durante o dia (informação por minuto).....	117
Figura 48 - Dados coletados durante a noite (informação por 15 minutos).....	118
Figura 49 - Dados coletados durante o sono (informação por minuto).....	118
Figura 50 - Dados coletados durante o sono (informação por 15 minutos).....	119
Figura 51 - Desvio padrão da aceleração por atividade.	120
Figura 52- Número de passos por minuto coletados ao longo do dia.	122
Figura 53 - Média do número de passos por 15 minutos.	122
Figura 54 - Modelo de um neurônio artificial.	137
Figura 55 – Funções de ativação: a) degrau; b) logística.....	138
Figura 56 - Fronteira de decisão da Perceptron.	139
Figura 57 - Perceptron de múltiplas camadas (MLP).	140

SUMÁRIO

1.	INTRODUÇÃO	19
1.1.	JUSTIFICATIVA	19
1.2.	MOTIVAÇÃO	21
1.3.	RECONHECIMENTO DE ATIVIDADES.....	22
1.4.	ESCOPO DO TRABALHO.....	22
1.5.	OBJETIVOS	23
1.5.1.	Objetivo Geral	23
1.5.2.	Objetivos Específicos	23
1.6.	ORGANIZAÇÃO DO TRABALHO	24
2.	SISTEMAS VESTÍVEIS DE MONITORAMENTO REMOTO.....	26
2.1.	CARACTERÍSTICAS DE SISTEMAS VESTÍVEIS	26
2.2.	TECNOLOGIAS DE COMUNICAÇÃO PARA SISTEMAS VESTÍVEIS	29
2.2.1.	Comunicação de curta distância.....	30
2.2.1.1.	Bluetooth Low-Energy (BLE)	33
2.2.2.	Comunicação de longa distância.....	35
2.3.	REQUISITOS DOS DISPOSITIVOS VESTÍVEIS.....	35
3.	RECONHECIMENTO E MONITORAMENTO DE ATIVIDADES.....	37
3.1.	RECONHECIMENTO DE ATIVIDADES COM ACELEROMETRIA.....	37
3.2.	PROCESSO DE RECONHECIMENTO DE ATIVIDADES HUMANAS.....	39
3.2.1.	Aquisição de dados.....	40
3.2.2.	Pré-processamento	40
3.2.3.	Segmentação	41
3.2.4.	Extração e seleção de características	41
3.2.5.	Classificação.....	43

3.2.5.1.	Árvore de decisão.....	43
3.2.5.2.	k-Vizinhos Mais Próximos (k-NN)	44
3.2.5.3.	Naive Bayes	45
3.2.5.4.	Modelo Oculto de Markov (HMM).....	46
3.2.5.5.	Máquina de Vetores de Suporte (SVM).....	47
3.2.5.6.	Redes Neurais Artificiais (ANN).....	47
3.3.	APLICAÇÕES DE MONITORAMENTO REMOTO DE ATIVIDADES.....	49
3.3.1.	PREVENÇÃO E MONITORAMENTO DE DOENÇAS CRÔNICAS	49
3.3.2.	MONITORAMENTO DE TRANSTORNO AFETIVO BIPOLAR	51
4.	SISTEMA PROPOSTO	53
4.1.	ESTRUTURA E FUNCIONAMENTO.....	53
4.1.1.	Abordagem A₁ – HAR	55
4.1.2.	Abordagem A₂ – Desvio padrão da aceleração	56
4.1.3.	Abordagem A₃ – Contador de passos	58
4.2.	HARDWARE.....	59
4.2.1.	Alimentação e proteção	60
4.2.2.	Microcontrolador	61
4.2.3.	Acelerômetro	62
4.2.4.	Módulo Bluetooth Low Energy (BLE)	63
4.2.5.	Placa de Circuito Impresso.....	65
4.2.6.	Protótipo.....	65
4.3.	FIRMWARE	67
4.3.1.	Algoritmo da abordagem A₁	68
4.3.2.	Algoritmo da abordagem A₂	69

4.3.3.	Algoritmo da abordagem A₃	70
4.4.	APLICATIVO MÓVEL.....	71
4.4.1.	Aplicativo móvel da abordagem A₁	72
4.4.2.	Aplicativo móvel da abordagem A₂	73
4.4.3.	Aplicativo móvel da abordagem A₃	74
4.5.	APLICAÇÃO PARA ANÁLISE DOS DADOS.....	75
5.	PROCESSAMENTO DOS DADOS	77
5.1.	AQUISIÇÃO DOS DADOS	77
5.2.	PROCESSO DE RECONHECIMENTO DE ATIVIDADES HUMANAS.....	78
5.2.1.	Segmentação	81
5.2.2.	Extração e seleção de características	83
5.2.3.	Classificação	84
5.2.3.1.	Perceptron de múltiplas camadas (MLP).....	85
5.2.3.2.	Hierarquia de Perceptrons.....	86
5.2.3.3.	Outros classificadores	88
5.3.	MONITORAMENTO DE ATIVIDADE	89
5.3.1.	Desvio padrão da aceleração	89
5.3.2.	Contador de passos	90
6.	TESTES E RESULTADOS	93
6.1.	RECONHECIMENTO DE ATIVIDADES HUMANAS (HAR)	93
6.1.1.	Coleta de dados para implementação dos classificadores	93
6.1.2.	Validação cruzada	102
6.1.3.	Perceptron de múltiplas camadas (MLP)	102
6.1.3.1.	Definição do número de neurônios na camada oculta.....	103

6.1.3.2.	Definição da taxa de aprendizagem	103
6.1.3.3.	Definição da precisão	104
6.1.3.4.	Desempenho da rede MLP	104
6.1.4.	Hierarquia de Perceptrons.....	107
6.1.4.1.	Definição dos atributos por Perceptron	107
6.1.4.2.	Desempenho da Hierarquia de Perceptrons.....	108
6.1.5.	Outros classificadores	109
6.1.6.	Comparação do desempenho dos classificadores	111
6.1.7.	Classificador embarcado no dispositivo vestível.....	112
6.1.8.	Comparação com outros trabalhos	115
6.2.	MONITORAMENTO DE ATIVIDADES	116
6.2.1.	Desvio padrão da aceleração – Abordagem A ₂	116
6.2.2.	Contador de passos – Abordagem A ₃	120
7.	CONCLUSÕES	123
7.1.	CONTRIBUIÇÕES.....	124
7.2.	PUBLICAÇÕES CIENTÍFICAS.....	125
7.3.	TRABALHOS FUTUROS.....	126
	REFERÊNCIAS.....	127
	APÊNDICE A – REDES NEURAIS ARTIFICIAIS.....	137
	APÊNDICE B – RESULTADOS DO CLASSIFICADOR EMBARCADO	143

1. INTRODUÇÃO

1.1. JUSTIFICATIVA

A desaceleração do crescimento da população mundial, provocada pela redução da taxa de natalidade, é um fenômeno concomitante com o envelhecimento populacional. Globalmente, espera-se que o número de pessoas com 60 anos ou mais dobre até 2050 e triplique até 2100 (ONU, 2015). Este fato é resultante do aumento da expectativa de vida que se verifica nos últimos anos em virtude dos avanços da medicina. No Brasil, segundo dados do IBGE (2015), o envelhecimento populacional é um fenômeno já evidente e tende a se tornar ainda mais notável nas próximas décadas. A proporção de idosos de 60 anos ou mais subiu de 9,7% para 13,7% entre 2004 e 2014, e projeta-se que alcance 18,6% em 2030 e 33,7% em 2060.

Entre os idosos, como é natural, a prevalência de doenças crônicas é superior em relação ao restante da população e, adicionalmente, pessoas com idade elevada têm maior dificuldade em prover seus próprios cuidados à saúde, além de muitas vezes não encontrar o apoio familiar necessário. Particularmente sobre o Brasil, Garcez-Leme e Leme (2014) inferem de sua pesquisa que a estrutura de assistência geriátrica ainda é inadequada para enfrentar o desafio do envelhecimento populacional no país, já que há em torno de apenas mil geriatras (um para cada 22 mil idosos) e grande disparidade na distribuição desses profissionais, os quais se concentram em regiões mais desenvolvidas.

Além disso, o crescimento da população idosa implica um exponencial aumento dos custos de assistência médica, visto que o sistema de saúde deve ser capaz de atender a um número cada vez maior de pessoas com doenças crônicas, mantendo a qualidade do atendimento. Ademais, os desenvolvimentos recentes de novas técnicas de diagnóstico e descobertas de novos remédios acarretam um crescimento na demanda por recursos médicos e de cuidados à saúde. As questões acima citadas são os principais fatores que exigem uma transformação no sistema de saúde. Entretanto, não apenas os idosos seriam beneficiados por esta transformação, já que qualquer pessoa que sofra de uma doença crônica, para a qual seja necessário um

monitoramento contínuo, seria beneficiada por um sistema de saúde dinâmico, proativo e preventivo.

Gradualmente, o atual sistema de saúde centrado no hospital, com foco em diagnóstico e tratamento, está mudando sua base para um sistema centrado no paciente, com ênfase em detecção de fatores de risco, diagnóstico precoce e tratamento precoce.

Conclusões a respeito da necessidade de uma transformação no sistema de saúde, com ampliação da telemedicina, suportada pela utilização de sensores biomédicos e tecnologia móvel, são notáveis já na última década. Lymberis (2003) defende que o monitoramento remoto do estado de saúde de um paciente por meio da transmissão de dados de sinais vitais para o provedor de saúde pode melhorar significativamente a prevenção, o diagnóstico e o tratamento de doenças, além da reabilitação.

Teng et al. (2008) mostram que com a transformação do sistema de saúde atual para um sistema participativo, preventivo, pervasivo e personalizado, espera-se que os serviços de assistência médica sejam acessíveis a todos, quando e onde forem necessários, por meio de intervenções de telemedicina. Esta pode ser definida como o uso de técnicas modernas de Tecnologia de Informação e Comunicação (TIC) para o fornecimento de informação e atenção médica a pacientes e profissionais da saúde localizados à distância.

Assim, a telemedicina, do ponto de vista do paciente, envolve o uso de TIC para melhorar o atendimento ao usuário do sistema de saúde, superando as barreiras geográficas, e ampliando o acesso a assistência e informações médicas, também suportando a troca de informações entre os profissionais de saúde (WORLD HEALTH ORGANIZATION, 2010). Um dos campos da telemedicina abrange o uso de dispositivos vestíveis de medições biométricas, como monitores de frequência cardíaca, pressão sanguínea e nível de glicose no sangue, os quais são cada vez mais utilizados para acompanhar remotamente pacientes com doenças crônicas.

1.2. MOTIVAÇÃO

O contínuo progresso tecnológico nos permite trabalhar com sensores e dispositivos microprocessados miniaturizados, de cada vez menor consumo energético e com novas tecnologias de comunicação sem fio. Estes avanços, aliados ao processamento inteligente da grande quantidade de informações coletadas por esses dispositivos, permitem a criação de uma plataforma eficiente para um sistema de saúde focado no paciente. Desta forma, soluções modernas de engenharia eletrônica e biomédica e de TIC podem contribuir para a ampliação e consolidação da telemedicina como uma ferramenta mais presente na assistência à saúde. Entre as possíveis soluções, duas tecnologias emergentes têm grande capacidade de impulsionar a disseminação da telemedicina: *Big Data* e Internet das Coisas (IoT, do inglês *Internet of Things*).

Big Data refere-se a um grande conjunto de dados gerados por elementos de aquisição de dados que se multiplicam rapidamente, produzindo um imenso volume de informações, o qual muitas vezes carece de análise. Chiavegatto Filho (2015) destaca que o uso de *Big Data* tem crescido em todas as áreas da ciência nos últimos anos e existem áreas promissoras para o uso em saúde, entre elas a IoT.

A IoT apresenta novas possibilidades de interação entre dispositivos e pessoas, e simplifica a coleta e a concentração de dados, bem como as ações tomadas sobre esses dados. De acordo com Bassi et al. (2013), IoT é uma superestrutura de rede emergente que conecta recursos físicos, *softwares* e pessoas. Além disso, quando totalmente consolidada, a IoT permitirá um ecossistema de aplicações e serviços inteligentes que pretende melhorar e simplificar a vida do cidadão.

Neste contexto, há algumas tendências de aplicações. Segundo Chiavegatto Filho (2015), uma possibilidade promissora será o uso de *wearables* (*vestíveis*), que são objetos eletrônicos conectados ao corpo que poderão identificar a iminência de infartos e acidentes vasculares antes mesmo do conhecimento do próprio indivíduo.

Além disso, aplicações de IoT podem oferecer a possibilidade de serviços médicos não só aos pacientes, mas também aos especialistas, os quais precisam de informação para prosseguir com a avaliação médica. Neste domínio, a IoT torna a

interação humana muito mais eficiente, pois permite não apenas a localização, mas também o rastreamento e o monitoramento de pacientes (BASSI et al., 2013).

Apesar dessas novas tecnologias oferecerem novas oportunidades e possibilidades de soluções na assistência médica, há ainda dois elementos importantes a serem melhor estabelecidos, que são a padronização e a privacidade. Adicionalmente, é importante integrar todas essas ideias como uma solução global para a definição e padronização da IoT como uma ferramenta de atenção à saúde. E ainda, ressaltam Yin et al. (2016), como em um sistema baseado em IoT a coleta, a exploração e o fornecimento de dados são realizados pela Internet, há grandes possibilidades de coleta inadequada de dados pessoais. Assim, a privacidade dos pacientes deve ser assegurada para evitar a identificação e o rastreamento não autorizados.

1.3. RECONHECIMENTO DE ATIVIDADES

Uma aplicação que usufrui do uso de dispositivos vestíveis e IoT para se tornar mais comum em nosso meio é o Reconhecimento de Atividades Humanas (HAR, do inglês *Human Activity Recognition*). Com o uso de sensores inerciais, como acelerômetro e giroscópio, e inteligência computacional, é possível identificar as atividades exercidas por uma pessoa. Adicionalmente, por meio de tecnologia móvel e da Internet, pode-se apresentar o histórico de atividades em um *smartphone* ou torná-lo acessível em uma plataforma *web*.

Reconhecer atividades físicas praticadas por uma pessoa pode ser importante em diferentes aplicações, como monitoramento de saúde de idosos e de pessoas acometidas por doenças crônicas ou cognitivas, visando a reabilitação, prevenção de crises e serviços de emergência. O HAR também pode ser aplicado em atividades esportivas e de lazer diárias, buscando motivar o usuário a praticar mais atividades, melhorando sua qualidade de vida.

1.4. ESCOPO DO TRABALHO

Este trabalho trata do desenvolvimento de um sistema de HAR e de monitoramento remoto como base para aplicações em saúde e bem-estar, que está sendo

desenvolvido no Núcleo de Tecnologia Assistiva (NTA) da Universidade Federal do Espírito Santo (UFES). O sistema consiste de um dispositivo vestível contendo um acelerômetro e um módulo de comunicação *Bluetooth Low Energy* (BLE), um aplicativo móvel para *smartphone*, para interação com o usuário, e uma aplicação de computador para visualização dos dados coletados transmitidos por e-mail. Apresentam-se três abordagens distintas, sendo a primeira delas o sistema de HAR, e as demais um sistema de monitoramento da intensidade das atividades realizadas pelo usuário ao longo do dia.

Encontram-se no escopo deste trabalho a concepção da solução, o desenvolvimento do *hardware* e do *firmware* embarcado no dispositivo vestível, o desenvolvimento do aplicativo móvel para o sistema operacional Android, e a implementação da aplicação de computador para visualização dos dados gerados. Também fazem parte do escopo o tratamento e o processamento inteligente dos dados do acelerômetro para classificação das atividades realizadas pelo usuário, bem como a avaliação dos resultados do classificador.

Ressalta-se que o uso de uma arquitetura padrão de IoT e requisitos de segurança e privacidade dos dados coletados e transmitidos não foram incluídos no escopo deste trabalho, porém se almeja realizá-los em trabalhos futuros.

1.5. OBJETIVOS

1.5.1. Objetivo Geral

O objetivo principal deste trabalho é desenvolver um sistema de Reconhecimento de Atividades Humanas (HAR) e de monitoramento remoto de atividades, utilizando um dispositivo vestível composto por um acelerômetro, comunicação BLE e inteligência computacional embarcada.

1.5.2. Objetivos Específicos

Para concretização do objetivo principal, apresentam-se como objetivos específicos:

- Desenvolver o *hardware* do dispositivo vestível;
- Desenvolver o *firmware* do dispositivo vestível;
- Desenvolver o classificador para reconhecimento de atividades *off-line* e embarcado no dispositivo;
- Testar e avaliar os resultados do classificador de atividades *off-line* e quando embarcado no dispositivo;
- Desenvolver um algoritmo para monitoramento da intensidade de atividades realizadas pelo usuário;
- Desenvolver o aplicativo móvel para interação do usuário com o dispositivo vestível;
- Desenvolver um *software* para visualização dos dados coletados do usuário.

1.6. ORGANIZAÇÃO DO TRABALHO

Esta dissertação de mestrado apresenta inicialmente uma introdução acerca do contexto em que se encontra a solução proposta. Na sequência, são levantadas as pesquisas correlatas ao presente trabalho e suas contribuições. Em seguida, apresentam-se as etapas do desenvolvimento de cada parte componente do sistema e suas características. Finalmente, são expostos os resultados alcançados, as conclusões e as contribuições do trabalho desenvolvido. A divisão dos capítulos apresenta-se da seguinte forma:

- Introdução – são apresentados fatores que evidenciam a necessidade de transformação do sistema de saúde, em busca de maior atenção ao paciente individualmente. Destacam-se as tecnologias recentes que podem suportar o aprimoramento da telemedicina com o uso de dispositivos vestíveis, e por fim são definidos o escopo e os objetivos do trabalho.
- Sistemas vestíveis de monitoramento remoto – neste capítulo são abordadas as características de um sistema de monitoramento remoto com dispositivos

vestíveis, bem como os requisitos essenciais para sua implementação. Também são discutidas as diversas tecnologias de comunicação sem fio aplicáveis a esses sistemas.

- Reconhecimento e monitoramento de atividades – neste capítulo as principais tecnologias empregadas em sistemas vestíveis para reconhecimento de atividades são apresentadas, tal como suas vantagens e desvantagens. Além disso, são abordadas as técnicas utilizadas em HAR e discutidos seus resultados. Finalmente, abordam-se duas aplicações em que o sistema proposto neste trabalho apresenta-se como solução.
- Sistema proposto – neste capítulo inicialmente apresenta-se o sistema como um todo e seu funcionamento em suas diferentes abordagens. A seguir, cada parte componente do sistema proposto é detalhadamente descrita: o *hardware*, o *firmware*, o aplicativo móvel e o *software* para visualização dos dados.
- Processamento de dados – neste capítulo, a princípio, abordam-se as técnicas de processamento de sinais aplicadas aos dados coletados. Em seguida, todos os estágios do desenvolvimento do classificador são explanados, incluindo a seleção do algoritmo, a coleta de dados, o treinamento e a inserção do classificador no microcontrolador.
- Testes e resultados – neste capítulo mostram-se os testes realizados para validação do algoritmo classificador de atividades, bem como os resultados alcançados *off-line* e quando embarcado no microcontrolador.
- Conclusões – finalmente, são discutidos os benefícios do sistema proposto, suas principais características e as possíveis melhorias a serem empregadas em trabalhos futuros. Também são abordados os resultados da classificação, tanto *off-line* como *on-line*. Por últimos, são levantadas as principais contribuições do trabalho.

2. SISTEMAS VESTÍVEIS DE MONITORAMENTO REMOTO

Este capítulo aborda as principais características de um sistema de monitoramento remoto de saúde baseado em dispositivos vestíveis, sendo discutidos os principais requisitos para o desenvolvimento desses dispositivos, incluindo as características físicas e as tecnologias de comunicação empregadas.

2.1. CARACTERÍSTICAS DE SISTEMAS VESTÍVEIS

Os sistemas formados por dispositivos vestíveis monitoram e armazenam informações em tempo real sobre a condição fisiológica e os movimentos de uma pessoa. Sistemas baseados em tecnologia vestível incluem diferentes tipos de sensores flexíveis, que podem ser integrados em roupas, fitas elásticas ou diretamente ligados ao corpo humano (MAJUMDER; MONDAL; DEEN, 2017). Outros exemplos são sensores utilizados em relógios, luvas, anéis, pulseiras (TENG et al., 2008), óculos, chapéus, calçados e cintos (SUZUKI, 2013). A Figura 1 apresenta alguns exemplos de dispositivos vestíveis.

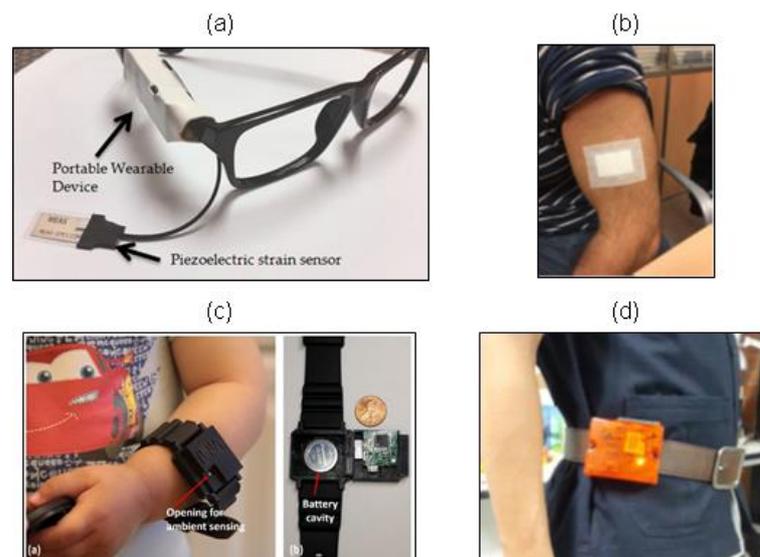


Figura 1 - Exemplos de dispositivos vestíveis.

Fonte: Farooq; Sazonov (2016); Braam et al. (2015); Vicente et al. (2016); Nuttaitanakul; Leauhatong (2015).

Como descrito por Pantelopoulos e Bourbakis (2010), possíveis parâmetros fisiológicos coletados por esses sensores são frequência cardíaca, pressão sanguínea, temperatura, saturação de oxigênio no sangue (SpO₂), frequência respiratória, eletrocardiograma (ECG), entre outros. O monitoramento de movimentos também tem sido amplamente empregado em diferentes aplicações médicas (AVCI, 2010; MUNOZ-ORGANERO, 2016; BILLIET, 2016).

A Figura 2 apresenta a estrutura genérica de um sistema de monitoramento remoto baseados em tecnologia vestível, onde o primeiro quadro mostra exemplos de parâmetros monitorados pelos sensores. Possíveis localizações dos dispositivos no corpo do usuário são destacadas pelo corpo do usuário. Os sinais coletados devem ser transmitidos via comunicação sem fio para um acumulador local, que pode ser, por exemplo, um microcontrolador, um *smartphone*, um *tablet* ou um computador.

Este acumulador (quadro central), por sua vez, pode processar ou armazenar as informações, exibi-las ao usuário em uma interface gráfica e enviá-las a um servidor remoto, via Internet, para acesso do profissional de saúde. O acumulador também pode ser um dispositivo vestível, atuando como um nó central que recebe dados de uma rede de sensores no corpo, chamada de *Body Sensor Network* (BSN).

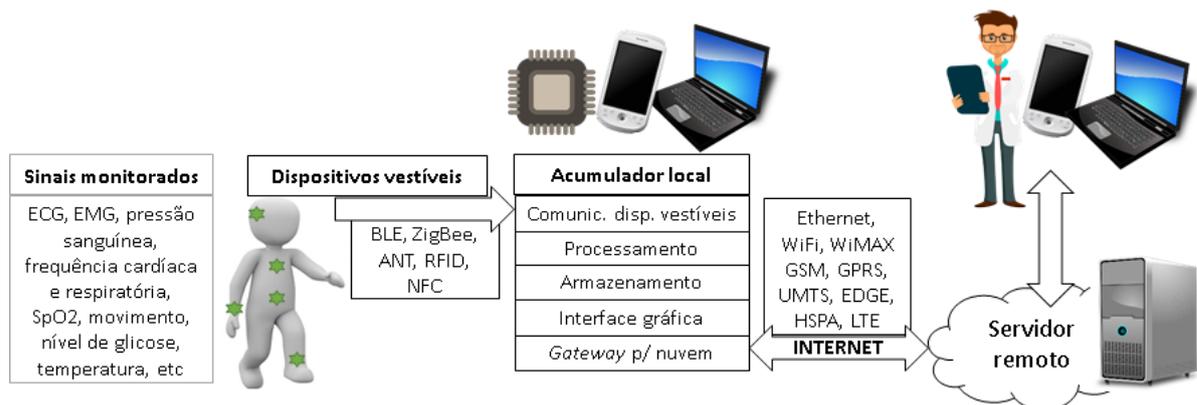


Figura 2 - Estrutura genérica de um sistema vestível.

Como se pode observar na Fig. 2, diferentes tipos de comunicação podem ser empregados, tanto local para um acumulador, como à distância para um servidor remoto. Uma aplicação *web* busca os dados no servidor remoto e os disponibiliza ao provedor de saúde, ao médico e ao próprio paciente. Encontram-se a seguir exemplos

de aplicações de monitoramento remoto de pacientes propostas recentemente na literatura, que se baseiam nessa estrutura.

Nemati, Deen e Mondal (2012) apresentam um sistema de eletrocardiograma (ECG) capacitivo vestível integrado a uma camisa, que não exige contato dos eletrodos com a pele, promovendo maior conforto ao usuário. Após instrumentação e processamento local, os autores escolheram o protocolo ANT para comunicação com um computador, que armazena e disponibiliza os dados processados para o usuário. Os autores defendem que o tamanho e o peso reduzidos e a boa qualidade do sinal coletado, somado ao fato de não incomodar o usuário, fazem do dispositivo um bom candidato ao monitoramento de longo-prazo via ECG.

Buscando facilidade de uso e extremamente baixo consumo energético, Vicente et al. (2016) apresentam um *biopatch* para medição de temperatura corporal, empregando *Near Field Communication* (NFC) para transmitir os dados armazenados a um *smartphone* ou a um leitor NFC. O *biopatch* é encapsulado com uma gaze para evitar o contato elétrico com a pele do usuário, e fixado com adesivo medicinal para garantir boa fixação. Já a tecnologia NFC garante baixo consumo energético e maior segurança na transmissão dos dados, pois não transmite continuamente e se conecta apenas ao leitor que se aproximar a poucos centímetros do dispositivo.

O Empatica E3 (GARBARINO et al., 2014) é um dispositivo vestível pequeno, leve e confortável, com múltiplos sensores e comunicação Bluetooth Low Energy (BLE), utilizado como uma pulseira. O sistema permite transferência de dados em tempo real, por meio de um aplicativo móvel que recebe os dados coletados via BLE, e os transmite para um servidor. Um *software* processa os dados e os apresenta ao usuário. De acordo com os autores, o dispositivo passou por testes de segurança e interferência eletromagnética e tem sido utilizado por pesquisadores em todo o mundo para criar aplicações customizáveis em telemedicina.

Infere-se dos trabalhos citados anteriormente a importância em garantir comodidade ao usuário ao utilizar um sensor vestível ou diretamente conectado a seu corpo. Este sempre deve ser leve, pequeno e não pode incomodar o usuário. Adicionalmente, nota-se que os protocolos de comunicação escolhidos pelos autores (ANT, NFC e

BLE) são de baixo consumo energético, característica fundamental dos dispositivos vestíveis. Essas questões serão abordadas nas seções seguintes.

Outros exemplos de propostas recentes incluem o monitoramento de múltiplos parâmetros fisiológicos e transmissão de dados via *Global System for Mobile Communications* (GSM) (RUI; QI; CHUANG, 2016; MEGALINGAM et al., 2016), detecção de queda com acelerômetro via GSM (RIHANA; MONDALAK, 2016), monitoramento de ECG com comunicação ZigBee (WU; LI, 2015) e NFC (IZUMI et al., 2015), e monitoramento de saturação de oxigênio no sangue, utilizando diferentes tecnologias de comunicação – *General Packet Radio Services* (GPRS), WiFi ou ZigBee – para acompanhamento de atletas (FU; LIU, 2015).

É notável que se encontram na literatura propostas com distintas tecnologias de comunicação, selecionadas de acordo com os requisitos da aplicação. Diante de uma heterogeneidade de tecnologias e protocolos de comunicação utilizados nos sistemas vestíveis, Spano, Pascoli e Iannaccone (2016) apresentam uma proposta que busca padronização. Trata-se de um sistema de monitoramento de ECG de longo-prazo que integra o sistema a uma infraestrutura padrão de IoT, permitindo que este seja incorporado a outros sistemas de monitoramento. O servidor IoT converte os dados brutos provenientes de diferentes sensores em um formato padrão, e então, torna os dados disponíveis a aplicações e usuários. A grande vantagem apresentada é a possibilidade de se utilizar diferentes tipos de comunicação entre os sensores e o *gateway*, tornando o sistema mais flexível.

A próxima seção aborda os principais protocolos de comunicação utilizados em sistemas de monitoramento remoto com dispositivos vestíveis, tanto para comunicação local, como de longo alcance. Será destacada a tecnologia BLE, a qual foi adotada neste trabalho.

2.2. TECNOLOGIAS DE COMUNICAÇÃO PARA SISTEMAS VESTÍVEIS

Os sinais fisiológicos medidos pelos sensores vestíveis passam por dois estágios de comunicação para entregar os dados ao servidor remoto. No primeiro estágio, emprega-se um protocolo de comunicação local para transmitir os dados para um nó

central. Este nó pode ser um dispositivo móvel ou um computador, e geralmente tem como funções processar os dados, mostrá-los ao usuário e transmiti-los até o servidor remoto. A próxima etapa é a transmissão de longa distância, que pode ocorrer via Internet ou comunicação celular (MAJUMDER; MONDAL; DEEN, 2017).

Omre (2010) definiu uma série de requisitos relativos à comunicação sem fio para um sistema de monitoramento remoto de saúde:

- Interoperabilidade – garantia que os produtos de diferentes fabricantes se comuniquem entre si.
- Baixo consumo energético – para permitir que os dispositivos de monitoramento sejam capazes de permanecer por meses ou anos alimentados por bateria, reduzindo manutenção e custo.
- Compatibilidade – dispositivos de radiofrequência devem funcionar no mesmo meio que outros transmissores, sem causar interferência eletromagnética a dispositivos eletrônicos sensíveis.
- Privacidade – a transmissão de dados deve ser segura para garantir que informações pessoais não sejam acessadas indevidamente.
- E os sensores devem se comunicar com a Internet ou com a rede celular para que a informação chegue remotamente aos profissionais de saúde.

Os desenvolvedores de sistemas vestíveis integrados à nuvem têm um amplo grupo de protocolos de comunicação disponíveis que podem ser utilizados em suas aplicações. Na última década, protocolos de baixo consumo energético, que atendem a alguns ou a todos esses requisitos levantados por Omre (2010), foram estabelecidos comercialmente, e serão abordados nesta seção.

2.2.1. Comunicação de curta distância

Em relação à comunicação de curta distância, as principais tecnologias de transmissão de dados utilizadas são: BLE, ZigBee, ANT, NFC e *Radio Frequency Identification* (RFID).

Bluetooth é uma popular tecnologia de comunicação de baixo consumo energético que é amplamente utilizada em dispositivos como *laptops*, *smartphones* e monitores *fitness* para comunicação de curta distância (MAJUMDER; MONDAL; DEEN, 2017). De acordo com o *site* da tecnologia, o Bluetooth versão 2.1 é indicado em aplicações de comunicação contínua de curto alcance. Já o BLE permite pequenos pulsos de conexão com alcance superior, fazendo este ideal para aplicações que não requerem conexão contínua, mas dependem de longa duração da bateria. Diversas propostas de aplicações recentes de sistemas vestíveis adotam o BLE como meio de comunicação com um *smartphone*, entre elas sistemas com múltiplos sensores embarcados em uma pulseira (BRAAM et al., 2015; GARBARINO et al., 2014) e em um pequeno dispositivo preso ao dedo (VOGT et al., 2016).

Por outro lado, ZigBee é uma tecnologia de comunicação sem fio de baixo consumo baseada no padrão IEEE 802.15.4. Suas principais aplicações são sensores inteligentes, automação residencial e unidades de controle remoto. Alguns trabalhos de sistemas médicos vestíveis adotam o ZigBee, como as propostas de Li e Warren (2012), Wu e Li (2015) e Spanò, Pascoli e Iannaccone (2016).

ANT é um protocolo proprietário de baixa taxa de transferência e baixo consumo, que opera em 2,4 GHz, com um alcance de 30 metros, e foi desenvolvido especialmente para dispositivos de monitoramento de saúde, bem-estar e esportes. Alguns exemplos na literatura são monitoramento de ECG (NEMATİ; DEEN; MONDAL, 2012), análise de marcha para reabilitação (JOHANSSON; SHEN; XU, 2011) e monitoramento com múltiplos sensores (MEHMOOD; CULMONE, 2015).

RFID é uma popular tecnologia de comunicação sem fio amplamente utilizada em aplicações de identificação de pessoas ou objetos, e opera em três faixas de frequência (125~134 kHz; 13,56 MHz; e 856~950 MHz). É formado por uma etiqueta, passiva ou ativa, e um leitor. A etiqueta passiva deve ser alimentada pela energia eletromagnética emitida pelo leitor no momento da leitura da informação, o que limita o alcance da conexão, enquanto a etiqueta ativa tem sua própria fonte de alimentação e, conseqüentemente, tem alcance superior.

No contexto de assistência médica, RFID, no geral, é escolhido por desenvolvedores de sistemas de rastreamento de pacientes em ambientes interiores (MADANIAN,

2016; LÓPEZ-SORIANO; PARRÓN, 2014), mas há alguns anos já vem sendo usado também integrado a sensores para transmitir informações fisiológicas (CATARINUCCI; COLELLA; TARRICONE, 2010).

NFC é um ramo da faixa *High Frequency* do RFID (13,56 MHz) e tem alcance em torno de 5 cm, fazendo esta ser considerada uma tecnologia de comunicação sem fio bastante segura. É bastante empregada em troca de informações entre *smartphones*, em pagamentos sem contato com cartões de crédito, e para obter informações adicionais sobre um objeto em uma loja ou uma exposição, por exemplo. Em monitoramento de saúde com sensores vestíveis, NFC normalmente é adotado em sistemas onde a coleta dos dados do dispositivo vestível é realizada apenas quando o usuário deseja (IZUMI et al., 2016; VICENTE et al., 2016). Neste caso, um *smartphone* ou um leitor NFC deve ser aproximado do dispositivo para aquisição dos dados armazenados na memória.

WiFi não é uma boa opção como meio de comunicação entre os sensores e o acumulador local, pois seu consumo é grande comparado ao dos demais protocolos. Entretanto, é uma tecnologia amplamente adotada como meio de comunicação com a Internet para levar os dados coletados até um servidor remoto. Este caso será abordado na próxima seção.

Entre as tecnologias citadas, ANT, ZigBee e BLE geralmente são as mais adequadas a serem empregadas para comunicação entre sensores vestíveis e acumulador local, principalmente por seu baixo consumo energético e pelo alcance superior aos protocolos NFC e RFID.

De acordo com Omre (2010), ZigBee tem potencial para uso em monitoramento remoto de saúde, entretanto, uma desvantagem é a baixa taxa de transferência de dados, que aumentaria em quatro vezes o tempo para transferir uma quantidade de informação, quando comparado ao BLE. Em relação ao protocolo ANT, a vantagem do BLE nesse quesito é ainda maior.

Além disso, uma importante vantagem da tecnologia BLE sobre ZigBee e ANT é o fato daquela ter sido amplamente adotada pelos fabricantes de *smartphones*, *tablets*, e *laptops*. Portanto, os sistemas que usam esses dispositivos como acumulador local

têm o BLE como opção mais adequada para atuar como meio de comunicação com os sensores vestíveis. Este foi um fator determinante na escolha do BLE como tecnologia de comunicação local neste trabalho.

2.2.1.1. Bluetooth Low-Energy (BLE)

A tecnologia Bluetooth opera na frequência *Industrial Scientific Medical* (ISM) em 2,4 GHz, e define 40 canais de radiofrequência com 2 MHz de espaçamento. Existem dois tipos de canais no Bluetooth: *advertising channels* e *data channels*. *Advertising channels* são usados para descoberta de dispositivos, estabelecimento de conexão e transmissão *broadcast*, já os *data channels* são utilizados para comunicação bidirecional entre dispositivos conectados (GOMEZ; OLLER; PARADELLS, 2012).

O modelo do protocolo Bluetooth é composto por duas partes principais: *Controller* e *Host*. O *Controller* compreende a camada física e a camada de enlace, e é geralmente implementada em um pequeno *System-on-Chip* (SoC) com o circuito de radiofrequência integrado. O *Host* é executado em um processador de aplicação e inclui as camadas superiores do protocolo. A comunicação entre o *Controller* e o *Host* é chamada de *Host Controller Interface* (HCI) (BLUETOOTH, 2017). A Figura 3 apresenta a pilha do protocolo Bluetooth.

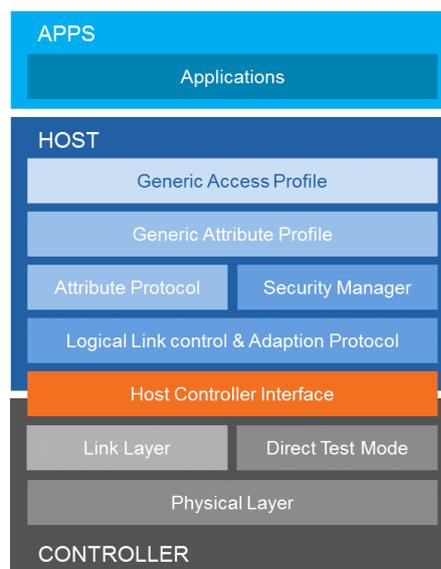


Figura 3 - Pilha do protocolo Bluetooth.

Fonte: Bluetooth, 2017.

Dois dispositivos são definidos na camada de enlace (*Link Layer*) do protocolo Bluetooth: o mestre e o escravo. O mestre pode gerenciar múltiplas conexões com diferentes escravos, enquanto cada escravo pode se conectar a apenas um mestre. Portanto, a rede composta por um mestre e seus escravos segue uma topologia estrela. O mestre atua como *initiator*, fazendo o papel de cliente, enquanto o escravo é o *advertiser*, o servidor. Para economizar energia, o escravo permanece no modo *sleep* e periodicamente desperta para checar se há pacotes disponíveis enviados pelo mestre.

As camadas *Generic Access Profile* (GAP) e *Generic Attribute Profile* (GATT) apenas existem nas implementações de BLE. Resumidamente, o GATT define formas padrões que os serviços, as características e os descritores podem ser descobertos e usados para permitir que os dispositivos BLE transfiram dados (BLUETOOTH, 2017). Um serviço é um conjunto de características e pode ser, por exemplo, um sensor de um determinado parâmetro. Neste caso, o serviço poderia ter como característica a medida deste parâmetro, e os descritores da característica poderiam ser o valor medido, a faixa aceitável e a unidade da medida.

Vários fabricantes desenvolvem módulos que implementam o *hardware* e o *firmware* necessários para construção do protocolo BLE em um SoC. Há diversos módulos disponíveis no mercado com um SoC BLE, e circuitos de radiofrequência, de potência e de comunicação serial para serem facilmente integrados a um produto. A Figura 4 mostra alguns desses módulos disponíveis no mercado: HM-10 da empresa Jinan Huamao Technology (Fig. 3a), BC118 da Blue Creation (Fig. 3b), RN4020 da Microchip (Fig. 3c) e CYBLE-012012-10 da Cypress (Fig. 3d).

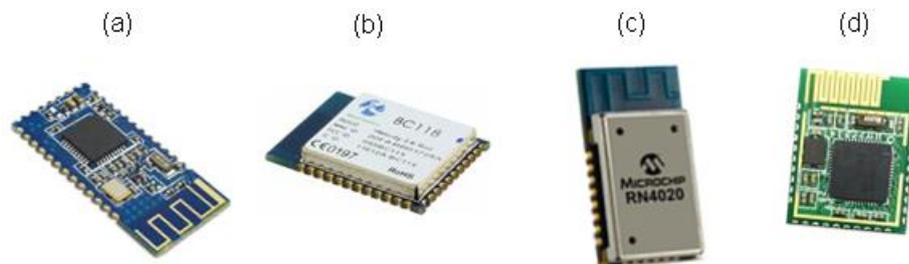


Figura 4 - Exemplos de módulos BLE.

Fonte: Itead (2017); Blue Creation (2017); Microchip (2017); Cypress (2017).

2.2.2. Comunicação de longa distância

O acumulador local pode realizar processamento dos dados coletados pelos sensores vestíveis para dar um *feedback* ao usuário do sistema, e deve atuar como um *gateway*, para entregar os dados coletados a um servidor remoto, como mostra a Fig. 2. Assim, uma aplicação pode buscar as informações nesse servidor para permitir a visualização pelo profissional de saúde. A comunicação entre o acumulador e o servidor remoto pode ocorrer pela Internet ou pela rede celular.

Quando o sistema utiliza a Internet para transmitir as informações, o acesso pode ser realizado via comunicação sem fio local – *Wireless Local Area Network (WLAN)* – ou metropolitana – *Metropolitan Wireless Area Network (MWAN)* – bem como via comunicação celular, utilizando as tecnologias que fazem parte das gerações 2G, 3G e 4G. Alguns exemplos são as propostas de Garbarito et al. (2014), Spano, Pascoli e Iannaccone (2016) e Yin et al. (2016).

Por outro lado, de acordo com a necessidade do sistema, podem-se transmitir os dados diretamente via rede celular para um *smartphone* ou *tablet*, ou outro dispositivo conectado a um modem adequado. Neste caso, também é possível enviar mensagens de texto para gerar um alerta. Temos como exemplos os sistemas propostos por Tseng et al. (2014), Rihana e Mondalak (2016) e Megalingam et al. (2016).

2.3. REQUISITOS DOS DISPOSITIVOS VESTÍVEIS

Por meio de sistemas vestíveis, os sinais biológicos de um indivíduo podem ser continuamente coletados e transmitidos com tecnologias de comunicação sem fio e, assim, os pacientes podem ser monitorados remotamente. Os dispositivos vestíveis que compõem esses sistemas geralmente são formados por um ou vários sensores, atuadores, um módulo de comunicação sem fio e um microcontrolador. Esses componentes devem atender a requisitos básicos exigidos por um sistema vestível, desde baixo consumo energético até estética agradável.

Majumder, Mondal e Deen (2017) pesquisaram diversas propostas de sistemas vestíveis e suas características, e afirmam que um dispositivo vestível deve ser

confortável, flexível, pequeno e quimicamente inerte e não-tóxico ao corpo humano. Os autores destacam ainda que esses dispositivos, sendo cada vez mais confortáveis e menos intrusivos, são apropriados para o monitoramento da saúde ou do bem-estar de uma pessoa sem interromper suas atividades diárias.

Ratificando o exposto acima, Pantelopoulos e Bourbakis (2010) destacam em sua extensa pesquisa que um dispositivo vestível deve ser leve, pequeno e não pode impedir movimentos ou ações do usuário. Além disso, o consumo energético deve ser minimizado para aumentar a autonomia do dispositivo. Kumari, Matthew e Syal (2016) revisaram as principais tendências em monitoramento de atividades e sinais biológicos utilizando dispositivos vestíveis, e alguns requisitos importantes a respeito dos dispositivos são apresentados a seguir:

- Estética – a aparência é tão importante que muitas empresas têm trabalhado em parceria com a indústria da moda para tornar os dispositivos mais atrativos.
- Conforto – os dispositivos vestíveis devem ser compactos e confortáveis para serem facilmente vestidos pelo usuário.
- Consumo energético – dispositivos vestíveis devem ser alimentados por bateria, visto que o monitoramento geralmente é contínuo; os requisitos de baixo consumo exigem que o microcontrolador e seu *firmware* tenham características especiais de redução de consumo energético.
- Comunicação sem fio – para monitoramento contínuo, conexão sem fio é essencial, já que o usuário não pode se movimentar e ficaria desconfortável com o uso de cabos; além disso, pode haver a necessidade de interação com mais de um dispositivo.

3. RECONHECIMENTO E MONITORAMENTO DE ATIVIDADES

Este capítulo apresenta aplicações de Reconhecimento de Atividades Humanas (HAR) e a importância de se monitorar as atividades de um indivíduo. São discutidas as principais características dos sistemas de HAR propostos recentemente na literatura, bem como as técnicas utilizadas no processo de reconhecimento de atividades. Por fim, abordam-se as aplicações para as quais se deseja construir uma base de sistema vestível neste trabalho.

O reconhecimento de atividades do dia-a-dia de uma pessoa é importante em diversas aplicações, entre elas o monitoramento de uma determinada doença crônica, o acompanhamento da reabilitação após uma hospitalização, a prevenção ou alerta de quedas de idosos, bem como a motivação à prática de esportes. Um sistema de HAR deve estar conectado a um dispositivo para dar *feedback* ao usuário e para tornar as informações coletadas disponíveis a um profissional da saúde.

Tradicionalmente, pesquisadores utilizam câmeras em aplicações de HAR, entretanto, esse tipo de abordagem é considerado intrusiva, e não respeita a privacidade do usuário em alguns casos (AVCI et al., 2010). Além disso, o uso de câmeras tem certas restrições, como as condições de iluminação e o local de instalação (XU et al., 2016). Avci et al. (2010) defendem que com os avanços da nanotecnologia e da comunicação sem fio de baixo consumo, os sistemas vestíveis baseados em sensores inerciais surgiram como uma alternativa de baixo custo, eficiente e que garante a privacidade do usuário.

3.1. RECONHECIMENTO DE ATIVIDADES COM ACELEROMETRIA

Entre as diversas tecnologias aplicáveis em HAR, os sensores inerciais, acelerômetros e giroscópios, são os mais utilizados. Além disso, o fato desses sensores estarem amplamente embarcados em *smartphones* os torna ainda mais populares atualmente (LIU et al., 2016). O acelerômetro, particularmente, tem sido bastante empregado neste contexto, tendo como exemplos os trabalhos de Machado

et al. (2015), Munoz-Organero e Lofti (2016), Farooq e Sazonov (2016), Billiet et al. (2016) e Zubair, Song e Yoon (2016).

O acelerômetro possui uma configuração massa-mola-amortecedor, a qual estabelece uma função de transferência entre o encapsulamento do sistema e a massa em movimento. O deslocamento da massa em relação ao invólucro pode ser detectado e convertido para um sinal elétrico de diferentes maneiras, de acordo com o tipo do acelerômetro, sendo os mais comuns o piezoresistivo, o piezelétrico e o capacitivo (XIE; FEDDER; SULOUFF, 2008).

Apesar dos acelerômetros terem se tornado bastante precisos ao longo dos anos, a identificação de atividades com robustez e precisão ainda apresenta uma série de desafios significativos. Um deles é que o acelerômetro em um dispositivo vestível geralmente apresenta dados com distorções provenientes de balanços e movimentos indevidos e quedas durante o uso. Adicionalmente, fatores como idade, altura, massa corporal e lesões podem influenciar na maneira na qual a pessoa caminha e executa atividades em geral (YAZDANSEPAS et al., 2016). Portanto, os algoritmos de HAR devem ser robustos contra perturbações provocadas por esses problemas.

Outro fator importante sobre o uso de acelerômetro em aplicações de HAR é o posicionamento do sensor. De acordo com Cornacchia et al. (2017), vários trabalhos de HAR baseados em acelerometria utilizam o sensor na cintura do usuário. Com a finalidade de detectar a movimentação global do indivíduo, essa posição central mostra-se muito mais estável em relação às extremidades, já que estas não necessariamente se movem em conjunto com o restante do corpo. Além disso, o posicionamento na cintura facilita a instalação do sensor em um cinto, por exemplo.

Cornacchia et al. (2017) também destacam que há autores que optam por posicionar o sensor nas extremidades do corpo, o que se tornou mais comum dada a recente popularização de pulseiras e relógios dotados de acelerômetro e integrados a *smartphones*. Entretanto, essas propostas geralmente exigem maior complexidade do algoritmo de aprendizagem para identificar certas atividades. Isso ocorre porque movimentos de braços e pernas, enquanto a pessoa encontra-se em repouso, podem promover um padrão de aceleração semelhante àquele gerado pela movimentação global.

Por outro lado, os *smartphones* têm sido bastante utilizados como dispositivo de sensoriamento em sistemas de HAR (WANG et al., 2015; SHOAIB et al., 2016), visto que possuem acelerômetro integrado e boa capacidade de processamento e de comunicação sem fio. Assim, podem dispensar o uso de sensores vestíveis adicionais e, por isso, os *smartphones* são considerados uma solução bastante atrativa e não-intrusiva por ser um dispositivo de uso comum no dia-a-dia das pessoas.

No entanto, devem-se considerar alguns fatores importantes a respeito do uso de *smartphones* como monitor de atividade. Primeiramente, para um monitoramento contínuo de fato, o usuário deve permanecer com o dispositivo em seu bolso, por exemplo, durante todo o dia, o que pode ser um incômodo e alguns casos impraticável. Ademais, monitorar o sono de uma pessoa pode se tornar inviável, visto que não é natural utilizar um *smartphone* no bolso enquanto se está dormindo. Já os dispositivos vestíveis são mais versáteis e podem ser facilmente utilizados continuamente, inclusive durante o sono.

Além disso, a bateria do *smartphone* deve ser compartilhada entre o uso comum pelo usuário e a aplicação executada em segundo plano para monitoramento. Logo, o consumo energético do *smartphone* pode ser prejudicado de acordo com o nível de processamento dos dados e com o uso de outros periféricos de sensoriamento, bem como de comunicação sem fio. Já um dispositivo vestível é desenvolvido para executar uma tarefa específica, respeitando o requisito de baixo consumo energético, e desse modo pode operar por longos períodos sem necessidade de recarga ou substituição de bateria.

3.2. PROCESSO DE RECONHECIMENTO DE ATIVIDADES HUMANAS

O processo de HAR é formado basicamente por etapas comuns a qualquer sistema de reconhecimento de padrões. A lista a seguir apresenta sequencialmente os principais estágios desse processo e suas funções no contexto de HAR utilizando dispositivos vestíveis com acelerômetro:

- Aquisição de dados: coletar os dados em uma taxa de amostragem adequada para a aplicação.

- Pré-processamento: reduzir ruído.
- Segmentação: definir o tamanho da janela de dados em que se deseja aplicar as etapas seguintes.
- Extração de características: extrair as características mais relevantes da janela de dados e definir um conjunto mínimo capaz de representar o padrão.
- Classificação: identificar a atividade por meio de um algoritmo classificador aplicado às características extraídas da janela de dados.

3.2.1. Aquisição de dados

De acordo com Khan et al. (2016), um sistema de HAR remoto de longo-prazo deve estabelecer uma relação ótima entre dados confiáveis e requisitos de duração de bateria e armazenamento. A taxa de amostragem na aquisição dos dados desempenha um papel fundamental nesse contexto, pois influencia diretamente o consumo energético, o volume de dados e os requisitos de banda de frequência para transmissão dos dados.

Gao, Bourke e Nelson (2014) avaliam a relação entre taxa de amostragem e acurácia de diferentes classificadores para HAR. Os autores mostram que, no caso proposto, a acurácia média aumenta em torno de 1% com uma taxa de amostragem a partir de 20 até 50 Hz, onde estabiliza. Entretanto, eles destacam que apesar do crescimento da acurácia, o aumento da taxa de amostragem também implica maior custo computacional, e, portanto, naquele caso, opta-se por uma taxa de amostragem de 20 Hz.

3.2.2. Pré-processamento

Devido à natureza dos sensores inerciais, os dados coletados devem passar por uma etapa de pré-processamento para redução de ruídos e eliminação de possíveis artefatos resultantes de movimentos indesejados do sensor. Geralmente, aplica-se um filtro passa-baixas, como de mediana, gaussiano ou laplaciano, para eliminação de ruído de alta frequência. Por outro lado, pode-se empregar um filtro passa-altas

quando se deseja distinguir a aceleração do corpo do indivíduo da aceleração gravitacional (AVCI et al., 2010).

3.2.3. Segmentação

A técnica de janela móvel é uma das abordagens mais utilizadas entre os métodos de segmentação em HAR (MUNOZ-ORGANERO; LOFTI, 2016; ZUBAIR; SONG; YOON, 2016; YAZDANSEPAS et al., 2016). Na aplicação dessa técnica, os dados coletados são divididos em várias janelas consecutivas, podendo haver sobreposição. Na sequência são extraídas as características do conjunto e, por fim, atribui-se uma atividade à janela, de acordo com o resultado da classificação.

A escolha do tamanho adequado da janela móvel tem papel fundamental no desempenho do processo de HAR. Com uma janela pequena é possível reconhecer uma atividade mais rapidamente, reduzir o processamento e, conseqüentemente, diminuir o consumo energético. Entretanto, uma janela muito reduzida pode não incluir um ciclo completo de atividade. Em contrapartida, uma janela grande geralmente é utilizada para reconhecimento de atividades complexas, porém implica maior custo computacional (XU et al., 2016).

3.2.4. Extração e seleção de características

A etapa de extração de características consiste em encontrar uma forma eficiente de representar os dados originais com um conjunto reduzido contendo suas características mais relevantes. A seleção adequada das características melhora de forma significativa o desempenho do algoritmo de classificação, enquanto a seleção de elementos redundantes e irrelevantes pode exigir maior processamento e deteriorar o desempenho do classificador.

Em um sistema de HAR, as características são extraídas da janela móvel de dados definida na etapa de segmentação, e podem ser divididas em duas categorias: domínio do tempo e domínio da frequência. A Tabela 1 apresenta as principais características utilizadas em propostas recentes.

Tabela 1 - Características dos dados por categoria.

Domínio	Característica
Tempo	Média
	Desvio padrão
	Variância
	Percentis
	Máximo
	Mínimo
	Raiz do valor quadrático médio
	Cruzamento por zero
	Número de picos
	Frequência
	Energia espectral
	Entropia espectral

Fonte: Avci et al., 2010; Gao; Bourke; Nelson, 2014.

No domínio do tempo, o uso da média e da variância como características é particularmente alto, devido à sua eficiente implementação. A média tende a detectar a postura local do corpo, enquanto a variância descreve quanto movimento está presente no sinal (LAERHOVEN; BERLIN; SCHIELE, 2009). Por outro lado, as características do domínio da frequência incluem a entropia e a energia da aceleração, e são geralmente utilizadas como medida da periodicidade de uma janela de dados (XU et al., 2016).

Adicionalmente ao processo de extração de características, pode-se aplicar uma técnica de redução de dimensionalidade, cujo objetivo é aumentar a precisão do classificador e reduzir o custo computacional. Há dois tipos de estratégias para executar essa tarefa: seleção de características e transformação de dados (AVCI et al., 2010). Na primeira estratégia, o desempenho do classificador é avaliado com diferentes conjuntos de características, até que se alcance o resultado ótimo. Em uma

outra estratégia, a transformação de dados se realiza aplicando técnicas como *Principal Component Analysis* (PCA) e *Local Discriminant Analysis* (LDA), que transformam o espaço de características, buscando maximizar a variância entre os dados e eliminando redundâncias.

3.2.5. Classificação

O vetor de características extraído dos dados é aplicado à entrada do algoritmo classificador de atividades. Entre as principais técnicas de classificação em sistemas de HAR encontram-se Árvore de Decisão, k-Vizinhos Mais Próximos (k-NN, do inglês *k-Nearest Neighbors*), Naive Bayes, Máquina de Vetores Suporte (SMV, do inglês *Support Vector Machine*), Modelo Oculto de Markov (HMM, do inglês *Hidden Markov Model*) e Redes Neurais Artificiais (ANN, do inglês *Artificial Neural Networks*) com arquitetura Perceptron de múltiplas camadas (MLP, do inglês *Multilayer Perceptron*) (AVCI et al., 2010; VRIES et al., 2010; MUNOZ-ORGANERO; LOFTI, 2016; XU et al., 2016; RONAO; CHO, 2016).

3.2.5.1. Árvore de decisão

Árvores de decisão classificam amostras fazendo com que estas trafeguem a partir de um nó raiz até um dos nós folhas, o qual fornece a classe da amostra. Cada nó da árvore determina uma regra de decisão sobre um atributo da amostra, e cada ramo descendente daquele nó corresponde a um dos possíveis valores do atributo. No processo de classificação, a amostra parte da raiz, sendo testada a cada nó, até alcançar uma folha (MITCHEL, 1997).

Na construção da árvore, primeiramente seleciona-se o melhor atributo a ser usado como variável na regra de decisão do nó raiz. Os ramos desse nó são criados com possíveis valores desse atributo, e as amostras de treinamento trafegam pelo ramo apropriado. O processo é repetido usando as amostras de treinamento associadas a cada ramo descendente para selecionar o melhor atributo a ser utilizado na regra de decisão de cada nó. Diferentes técnicas podem ser aplicadas ao processo de se encontrar o melhor atributo, de acordo com o algoritmo utilizado. Define-se um nó

como folha quando este recebe apenas amostras de treinamento de uma mesma classe, ou uma maioria suficiente definida pelo processo de treinamento.

Algumas propostas de sistemas de HAR empregam a Árvore de Decisão como classificação. No trabalho de Phan (2014), por exemplo, uma Árvore de Decisão com poda automática foi proposta para classificar cinco atividades (“ocioso”, “andando”, “correndo”, “pedalando” e “dirigindo”) utilizando um *smartphone* para coleta dos dados, e os autores obtiveram 98,1% de precisão média na classificação.

Por outro lado, Fan, Wang e Wang (2013) desenvolveram uma árvore de decisão para classificar cinco atividades (“em pé parado”, “andando”, “correndo”, “subindo escada” e “descendo escada”), utilizando oito parâmetros do domínio do tempo e dois do domínio da frequência. Esses parâmetros são extraídos dos dados de acelerometria, coletados com um *smartphone*. Os autores obtiveram 80,29% de acurácia de classificação.

3.2.5.2. k-Vizinhos Mais Próximos (k-NN)

O classificador k-NN memoriza o conjunto de treinamento e classifica uma nova amostra com base nas classes das amostras mais próximas àquela que se deseja classificar. A classe associada à amostra que se deseja classificar é aquela que se apresenta em maior número dentro do grupo composto por k vizinhos mais próximos. Diferentes métricas podem ser utilizadas para o cálculo da distância entre amostras, como a distância euclidiana, a distância de Mahalanobis, a distância de Chebychev e a similaridade cosseno, entre outras.

Paul e George (2015) utilizaram k-NN para reconhecimento de quatro atividades (“em pé”, “sentado”, “andando” e “correndo”), coletando dados com um *smartphone*, utilizando como características média, desvio padrão, valor máximo e valor mínimo, e obtêm 92% de acurácia. Trata-se de uma acurácia baixa, dados os tipos de atividades a serem classificados, considerados simples.

No trabalho de Awais, Palmerini e Chiari (2016) adotou-se o algoritmo k-NN como classificador para reconhecimento de 13 atividades, entre elas atividades complexas como “lavar louça”, “varrer” e “usar aspirador de pó”. As amostras utilizadas fazem

parte de uma base de dados de 19 indivíduos saudáveis, utilizando quatro dispositivos vestíveis contendo acelerômetro e giroscópio de três eixos em diferentes partes do corpo. As características extraídas de cada sensor são média, desvio padrão, variância, mediana, amplitude, RMS, curtose, obliquidade, energia e área do módulo do sinal (SMA, do inglês *Signal Magnitude Area*). Os autores alcançaram 97,38% de acurácia, entretanto, ressaltaram que quatro dispositivos vestíveis é um número relativamente grande em sistemas de HAR, visto que requisitos de usabilidade, autonomia de bateria e armazenamento de dados tornam-se mais críticos.

3.2.5.3. Naive Bayes

Em algumas aplicações, o desempenho do classificador Naive Bayes mostra-se comparável àquele alcançado por classificadores baseados em ANN e Árvore de Decisão (MITCHELL, 1997). A abordagem Bayesiana adotada em classificação de padrões baseia-se em associar uma nova amostra à classe com maior probabilidade de ocorrer, dados os atributos $\{x_1, x_2, \dots, x_n\}$ daquela amostra, ou seja, define-se a classe como mostra a Equação 1, sendo j o número de classes e n o número de atributos da classe.

$$C = \operatorname{argmax} [P(C_j | x_1, x_2, \dots, x_n)] \quad (1)$$

Com base no teorema de Bayes, pode-se reescrever a Equação 1 como:

$$C = \operatorname{argmax} \left[\frac{P(x_1, x_2, \dots, x_n | C_j) P(C_j)}{P(x_1, x_2, \dots, x_n)} \right] \quad (2)$$

Visto que o classificador Naive Bayes se baseia na suposição de que os atributos das amostras são condicionalmente independentes, dada a classe da amostra, pode-se reescrever a Equação 2 como:

$$C = \operatorname{argmax} \left[P(C_j) \prod_{i=1}^n P(x_i | C_j) \right] \quad (3)$$

Quando as amostras são caracterizadas por atributos numéricos, como é o caso deste trabalho, pode-se utilizar funções de densidade de probabilidade para calcular a probabilidade a priori dos atributos.

Um exemplo de aplicação de Naive Bayes em HAR é o trabalho de Ravi et al. (2005), proposto ainda na última década, no qual se desejava classificar oito diferentes atividades: “em pé”, “andando”, “correndo”, “subindo escada”, “descendo escada”, “sentando”, “usando o aspirador de pó” e “escovando os dentes”. Os dados foram coletados de um acelerômetro de três eixos localizado próximo à região pélvica, a uma taxa de amostragem de 50 Hz e com uma janela de dados de 5,12 segundos. As características extraídas de cada eixo foram média, desvio padrão, energia e correlação. A acurácia obtida foi de 98,86% quando treinado e testado com o mesmo indivíduo em dias diferentes, e 64% quando treinou-se com uma pessoa e testou-se com outra em dias diferentes. Nota-se que o classificador carece de uma generalização eficiente.

3.2.5.4. Modelo Oculto de Markov (HMM)

HMM é uma das mais populares técnicas de modelagem utilizadas em reconhecimento de padrões. Esta técnica é usada para gerar estados ocultos a partir dos dados observados. Seu objetivo principal é determinar a sequência de estados ocultos que correspondem à sequência de saídas observadas e aprender parâmetros do modelo do histórico desta sequência de saídas (KIM; ELAL; COOK, 2010).

Safi et al. (2016) propuseram um sistema de HAR, com um classificador baseado em HMM modificado (com regressão múltipla), para identificar 12 diferentes atividades, que incluem posições estáticas, mudanças de posição, além de “andando”, “subindo escada” e “descendo escada”. No trabalho utilizou-se uma base de dados coletados de seis indivíduos saudáveis utilizando três acelerômetros posicionados no peito, na coxa direita e no tornozelo esquerdo. Os autores mostraram que para um HMM comum, obtiveram uma média de 75,60% de acurácia, enquanto que para o classificador proposto obtiveram 87,43%.

3.2.5.5. Máquina de Vetores de Suporte (SVM)

SVM é uma técnica bastante utilizada em reconhecimento de padrões, e se baseia em encontrar o hiperplano ótimo de separação de classes, com a maior margem possível.

Anguita et al. (2012) aplicaram um classificador baseado em SVM com modificações, visando reduzir o custo computacional, para classificar seis diferentes atividades: “em pé”, “sentado”, “deitado”, “andando”, “subindo escada” e “descendo escada”. Os autores utilizaram um *smartphone* colocado na cintura do usuário para coleta dos dados de acelerometria, com taxa de amostragem de 50 Hz. Cada amostra é formada por uma janela de 2,56 segundos com 50% de sobreposição, e desta são extraídas 17 características. Obtiveram-se 89% de acurácia.

Tran e Phan (2016) utilizaram um classificador SVM comum para HAR em um cenário próximo àquele do trabalho de Anguita et al. (2012) apresentado anteriormente, com as mesmas seis atividades a serem classificadas. Também se replicam o tamanho de janela de dados, o percentual de sobreposição e a taxa de amostragem. Neste caso, o *smartphone* foi colocado no bolso do usuário e as características extraídas dos dados foram média, desvio padrão, valor máximo, valor mínimo, SMA, energia, amplitude interquartil e entropia. Obtiveram-se 89,59% de acurácia.

3.2.5.6. Redes Neurais Artificiais (ANN)

Uma rede neural é um processador distribuído com alto grau de paralelismo construído por simples unidades de processamento (neurônios), com capacidade de armazenamento de conhecimento e aplicação deste de forma generalizada. O aprendizado é adquirido pela rede por meio de um processo de treinamento, e as conexões entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento obtido (HAYKIN, 2008).

Basicamente, um modelo de neurônio artificial é formado por sinais de entrada, pesos sinápticos, um combinador linear, um limiar de ativação e uma função de ativação que gera a saída do neurônio. O combinador linear agrega os sinais de entrada,

ponderados pelos pesos, e o limiar de ativação. A função de ativação é aplicada sobre o potencial de ativação, para produzir a saída do neurônio dentro de um intervalo de valores razoáveis.

O modelo mais elementar de ANN é o Perceptron, formado por uma camada de entrada, e uma camada de saída composta por apenas um neurônio. A saída produzida pelo Perceptron assume apenas dois valores diferentes e trata-se de uma função linear. Assim, em uma aplicação de classificação de padrões, o Perceptron pode classificar um conjunto de amostras em apenas duas classes, que sejam linearmente separáveis por um hiperplano.

Por outro lado, uma rede MLP é formada por ao menos uma camada de neurônios oculta, entre a entrada e a saída, e suas camadas são constituídas de vários neurônios, que têm função de ativação não-linear. Essa arquitetura de ANN pode classificar um conjunto de amostras em diversas classes diferentes, mesmo que não sejam linearmente separáveis. A rede MLP tem sido aplicada com sucesso, ao longo dos anos, em problemas de classificação de padrões com alto grau de complexidade. O Apêndice A apresenta um conteúdo mais detalhado acerca das RNA, incluindo a estrutura das redes Perceptron e MLP, bem como seus processos de treinamento.

Classificadores baseados em ANN têm sido empregados com sucesso em sistemas de HAR. Vries et al. (2010) propuseram uma rede MLP para classificar cinco diferentes atividades (“andando”, “pedalando”, “usando a escada”, “em pé parado” e “sentado”), a partir dos parâmetros percentis-10, 25, 75 e 90, desvio absoluto, coeficiente de variabilidade e autocorrelação, extraídos dos dados de aceleração. Os autores obtiveram acurácia de 80,4%, 77,7% e 83% com o sensor usado no quadril, no tornozelo e ambos ao mesmo tempo, respectivamente.

Um outro exemplo é o trabalho de Lubina e Rudzki (2015), no qual os autores aplicaram uma rede MLP na classificação de atividades, obtendo acurácia de 86,20% entre as atividades “sentado”, “em pé”, “andando”, “subindo escadas” e “descendo escadas”, utilizando dados de dois acelerômetros, sendo um no quadril e outro no tornozelo. Já no trabalho de Lee et al. (2010), um classificador neural hierárquico formado por redes MLP foi proposto para classificar as atividades “deitado”, “sentado”, “em pé”, “andando”, “subindo escadas”, “descendo escadas”, “correndo” e “dirigindo”.

Os autores obtiveram 84,8% de acurácia de classificação de dados coletados com um acelerômetro utilizado no tórax do usuário.

Gao, Bourke e Nelson (2014) compararam cinco classificadores, aplicados em um sistema de HAR, para identificar cinco diferentes atividades: “em pé”, “sentado”, “deitado”, “andando” e “transição”, sendo esta última a mudança de uma posição estática para outra. Os autores utilizaram uma configuração com quatro acelerômetros, localizados no tórax, na cintura, no quadril e na coxa do usuário, sendo os dados coletados a uma taxa de 20 Hz. O classificador neural apresentou o melhor desempenho (96,8% de acurácia), seguido pela árvore de decisão (96,4%), k-NN (96,2%), SVM (92,7%) e Naive Bayes (89,5%). Apesar da alta acurácia obtido, é importante ressaltar que uma configuração com múltiplos sensores se torna pouco “invisível” ao usuário, exige mais recursos de processamento computacional e de autonomia de bateria, prejudicando sua aplicabilidade no monitoramento de longo-prazo contínuo.

3.3. APLICAÇÕES DE MONITORAMENTO REMOTO DE ATIVIDADES

Esta seção aborda duas aplicações de interesse: prevenção e monitoramento de doenças crônicas, e monitoramento de Transtorno Afetivo Bipolar (TAB). A importância do monitoramento de atividades nos dois contextos é discutida, e propostas correlatas ao presente trabalho são apresentadas.

3.3.1. PREVENÇÃO E MONITORAMENTO DE DOENÇAS CRÔNICAS

De acordo com Miragaya (2006), estudos epidemiológicos mostram que indivíduos ativos fisicamente vivem mais do que aqueles sedentários e apresentam menor tendência a desenvolver doenças crônicas, tais como doenças coronarianas, hipertensão arterial, diabetes tipo 2, osteoporose, câncer de cólon, ansiedade e depressão. Com o objetivo de reduzir os problemas relacionados ao sedentarismo, os dispositivos vestíveis de monitoramento de atividades físicas desempenham um papel fundamental, pois motivam o usuário a praticar mais atividades e a manter um estilo de vida saudável.

Adicionalmente, o uso de tecnologia emergente de biosensores pode contribuir para uma gestão mais eficiente de doenças crônicas, a qual pode resultar em diminuição na taxa de mortalidade, melhora da qualidade de vida, redução do número e do custo de consultas médicas, tratamento e hospitalizações de emergência (TOUMPARNIARIS et al., 2014).

Além disso, pessoas que foram hospitalizadas e necessitam de reabilitação podem usufruir de um monitoramento remoto durante sua recuperação. Os sensores vestíveis com tecnologia de comunicação sem fio monitoram as atividades realizadas pelo indivíduo, independentemente da localização do paciente, produzindo informação confiável e objetiva (APPELBOOM et al., 2014). Desta forma, um médico pode acompanhar remotamente a evolução do seu paciente em um processo de reabilitação.

Um exemplo é o trabalho de Billiet et al. (2016), que apresenta um estudo piloto de um sistema de avaliação automática da capacidade de realização de atividades por pacientes com doenças reumáticas e musculoesqueléticas. No caso proposto, o dispositivo vestível é composto por um acelerômetro de dois eixos, e é instalado no bíceps do usuário, e os dados são transferidos para um *tablet*. O objetivo é reconhecer uma série de movimentos executados, para avaliação da condição física do paciente.

No caso de idosos, o maior objetivo de sistemas vestíveis de monitoramento remoto é oferecer uma vida com maior independência e segurança, pois detecções precoces de uma situação perigosa, como uma queda, implicam em tratamento de forma mais imediata e, conseqüentemente, melhores resultados.

Nexte contexto, no estudo de Kang et al. (2010), foi desenvolvido um sistema de HAR de tempo real para reconhecer e monitorar os movimentos de idosos ou paciente que necessitem de assistência médica no dia-a-dia. Os autores propõem um sistema que utiliza um acelerômetro de três eixos facilmente instalado na cintura, que não impede que o usuário realize as atividades diárias. O sinal coletado é transferido para um computador local, no qual se aplica o processo de HAR.

3.3.2. MONITORAMENTO DE TRANSTORNO AFETIVO BIPOLAR

O TAB é caracterizado por episódios alternados de depressão e mania. A instabilidade de humor é associada a um alto risco de recaída e hospitalização. Os principais sintomas relacionados à depressão descritos por pacientes são: sono prolongado, necessidade de ficar sozinho e cansaço excessivo. Enquanto para mania, os sintomas mais marcantes são: dificuldade para dormir, ausência de necessidade de sono, pensamentos acelerados e aumento da expressão verbal (LOBBAN et al., 2011).

Evidências mostram que ensinar pacientes a reconhecer sintomas de uma recidiva pode prolongar o intervalo de recorrência e diminuir o número de hospitalizações, visto que a detecção precisa e precoce de sinais é decisiva para evitar uma crise (MORRISS et al., 2007).

Segundo Jamison e Akiskal (1983), alguns pacientes diagnosticados com TAB relatam não perceber qualquer sintoma precocemente, e quando essa percepção não ocorre a tempo, pode levar o paciente a sofrer consequências adversas. Portanto, com o intuito de promover a prevenção de recaídas, e visto que os principais sintomas relatados de depressão e mania são relacionados ao nível de atividade e à qualidade do sono, o uso de um sistema vestível de monitoramento remoto de atividades surge como uma solução.

Smartphones têm sido propostos como dispositivos de monitoramento para pacientes com TAB, utilizando seus diversos sensores embarcados. Um projeto bastante conhecido neste contexto é o Monarca (*Monitoring, Treatment and Prediction of Bipolar Disorder Episodes*), o qual utiliza o acelerômetro de um *smartphone* para monitorar atividades do usuário, e os serviços de ligação e mensagens para monitorar a atividade social. Resultados preliminares apontam que o sistema pode ser muito útil no dia-a-dia de pacientes com TAB, e seria uma grande vantagem sobre os formulários de papel utilizados para avaliação atualmente (PUIATTI et al., 2011).

O projeto Simba (*Social Information Monitoring for Patients with Bipolar Affective Disorder*) monitora o humor, a atividade física e a comunicação social do paciente, utilizando um *smartphone*. Como resultados, sintomas de depressão foram previstos pela queda de atividade social e física, enquanto sintomas de mania foram previstos

com diminuição da atividade física e aumento da atividade social no *smartphone*. (BEIWINKEL et al., 2016).

Entretanto, deve-se considerar uma desvantagem importante do uso do *smartphone* como monitor de atividades física e social, já que no próprio projeto Monarca foi relatado que a duração da bateria do *smartphone* foi de apenas 12 horas, mantendo ligados os sensores GPS, acelerômetro e os periféricos de comunicação WiFi e 3G, que são utilizados pelo sistema de monitoramento.

4. SISTEMA PROPOSTO

Este capítulo apresenta a estrutura do sistema proposto, incluindo o *hardware* e o *firmware* que compõem o dispositivo vestível, o aplicativo móvel para o sistema operacional Android e o *software* para visualização dos dados. Também são descritos os materiais, as ferramentas e os *softwares* utilizados no desenvolvimento das partes componentes do sistema.

4.1. ESTRUTURA E FUNCIONAMENTO

A Figura 5 apresenta o diagrama geral do sistema desenvolvido, no qual se pode observar o usuário utilizando o dispositivo vestível na altura da cintura, como um cinto, ou no punho, como uma pulseira. O dispositivo é composto basicamente por um acelerômetro, para coleta dos dados, um microcontrolador, para processamento dos dados coletados, e um módulo BLE, para transmissão dos dados para o *smartphone* do usuário. Do *smartphone*, os dados podem ser transferidos via e-mail para acompanhamento médico remoto.

Optou-se por enviar os dados coletados via e-mail por se tratar de uma técnica de implementação simplificada, porém suficiente para validação do sistema proposto neste trabalho.

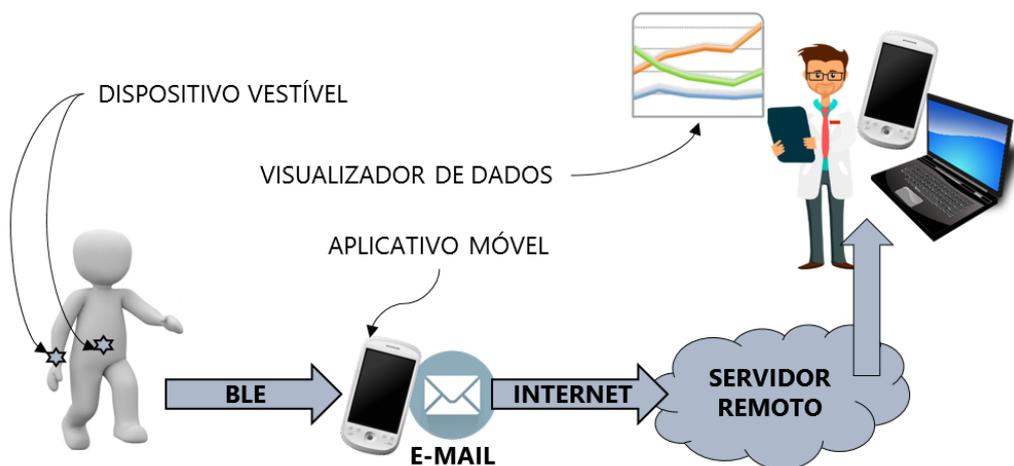


Figura 5 - Diagrama geral do sistema desenvolvido.

Diferentemente dos demais sistemas de HAR propostos na literatura recentemente (KANG et al., 2010; FAN; WANG; WANG, 2013; GAO; BOURKE; NELSON, 2014; LUBINA; RUDZKI, 2015), neste trabalho o processo de identificação da atividade ocorre no próprio dispositivo vestível. Portanto, é possível monitorar as atividades realizadas pelo usuário ao longo do dia, sem a necessidade de uso do *smartphone* para processar as informações coletadas. As informações processadas são armazenadas no dispositivo vestível e podem ser transmitidas no momento em que houver conexão com o *smartphone*, e deste com a Internet. Assim, não há a necessidade de o usuário manter o *smartphone* próximo durante todo o tempo para garantir um monitoramento, verdadeiramente, contínuo.

Foram desenvolvidas três abordagens para operação do sistema, como se apresenta na Tabela 2. Entre as abordagens, variam-se a localização de uso do dispositivo vestível, o algoritmo embarcado no microcontrolador e a forma de visualização das informações. Também foram associadas aplicações bases, que estão sendo desenvolvidas no NTA-UFES (abordagens A₁ e A₂), enquanto a abordagem A₃ pode funcionar como uma ferramenta auxiliar adicional para as duas primeiras aplicações.

Tabela 2 - Abordagens do sistema desenvolvido

Abordagem	Posição do dispositivo	Algoritmo	Apresentação da informação	Aplicação base
A ₁	Cintura	HAR	<i>Smartphone</i>	Acompanhamento e prevenção de doenças crônicas
A ₂	Punho	Desvio padrão	<i>Smartphone</i> e computador	Monitoramento de pessoas com TAB
A ₃	Cintura	Contador de passos	<i>Smartphone</i> e computador	-

Na abordagem A_1 , o dispositivo vestível conta com inteligência embarcada para reconhecer seis diferentes atividades e enviar a atividade identificada para o *smartphone* do usuário. Por outro lado, as abordagens A_2 e A_3 utilizam um algoritmo de monitoramento de intensidade de atividade embarcado no dispositivo vestível. Nessas abordagens o usuário recebe a informação do desvio padrão médio da aceleração (A_2) ou do número de passos executados (A_3) ao longo do dia no aplicativo móvel, e o parâmetro monitorado também pode ser enviado por e-mail para visualização de forma gráfica, e também para avaliação por um profissional da saúde utilizando um *software* de computador.

4.1.1. Abordagem A_1 – HAR

Na primeira abordagem, A_1 , o dispositivo vestível é utilizado na cintura, como um cinto, e o algoritmo inteligente embarcado é capaz de identificar seis diferentes atividades do cotidiano do usuário: “andando”, “correndo”, “subindo escada”, “descendo escada”, “em pé parado” e “sentado”. O processo completo de HAR desenvolvido, incluindo tratamento dos dados, segmentação, extração de características e classificação das atividades, é apresentado no Capítulo 5.

Neste trabalho, para validação do processo de identificação de atividades, o sistema de HAR foi implementado, incluindo um *feedback* ao usuário, em seu *smartphone*. O sistema funciona da maneira como se apresenta na Figura 6. Inicialmente, no aplicativo móvel, o usuário deve conectar o *smartphone* ao dispositivo vestível via BLE, e iniciar a classificação de atividades. O dispositivo, então, aplica o algoritmo classificador às características extraídas de uma janela de dois segundos de dados, como descrito no Capítulo 5. A atividade reconhecida é enviada para o *smartphone*, onde o usuário pode visualizar a informação. Essa operação é executada até que o usuário finalize a classificação de atividades.

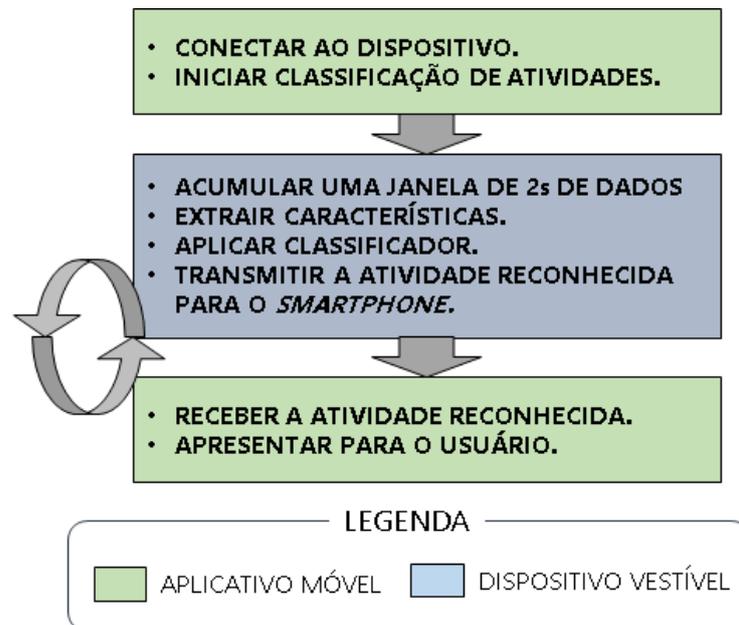


Figura 6 - Funcionamento da abordagem A₁.

O sistema remoto de HAR desenvolvido na abordagem A₁ será futuramente expandido para permitir a transferência das informações para o médico, e poderá ser utilizado como base nas aplicações de acompanhamento e prevenção de doenças crônicas. Além disso, também poderá ser usado em sistemas de reabilitação e motivação à prática de atividades físicas, entre outros. Nessas aplicações, as atividades realizadas são monitoradas ao longo do dia para avaliar o estilo de vida do usuário, ativo ou sedentário, e, adicionalmente, o sistema pode gerar sugestões de atividades de acordo com o comportamento do usuário.

4.1.2. Abordagem A₂ – Desvio padrão da aceleração

Na abordagem A₂, o usuário utiliza o dispositivo vestível no punho, o que torna o dispositivo mais “invisível” (mais confortável e mais discreto) ao usuário, já que é comum utilizar pulseiras ou relógio, de forma contínua, até mesmo para dormir. Assim, é possível monitorar também a qualidade do sono do usuário, em função dos movimentos realizados. No entanto, o uso de um algoritmo contador de passos, por exemplo, para o dispositivo instalado no punho é muito susceptível a falsos positivos, pois movimentos dos braços podem ser identificados como passos executados. Para superar esta dificuldade, exige-se um algoritmo inteligente de alto grau de

complexidade, o que inviabilizaria a implementação no microcontrolador utilizado neste trabalho.

Portanto, optou-se, neste caso, por um algoritmo que calcula o desvio padrão médio da aceleração do usuário a cada minuto. O desvio padrão mede a dispersão em torno da média de um sinal, e pode indicar a quantidade de movimento presente no sinal coletado, com base em conceitos adotados por Collins et al. (2015) e Rodríguez-Martins et al. (2017). Após a validação do funcionamento deste sistema, pretende-se futuramente avaliar a relação do desvio padrão com a intensidade das atividades realizadas ao longo do dia, visando utilizar essa abordagem, principalmente, no sistema de monitoramento de TAB em desenvolvimento no NTA-UFES.

O funcionamento do sistema apresenta-se na Figura 7. O usuário deve conectar o *smartphone* ao dispositivo vestível e iniciar o monitoramento. O dispositivo, então, calcula o desvio padrão de uma janela de um segundo da aceleração, acumula o somatório desse valor por um minuto, e salva a média na memória não-volátil do microcontrolador. Quando o usuário desejar, pode salvar os dados coletados no *smartphone* e os transmitir a um e-mail para avaliação remota. O arquivo de texto recebido por e-mail pode ser executado em uma aplicação de computador, que apresenta, de forma gráfica, o desvio padrão médio a cada minuto, ao longo do dia.

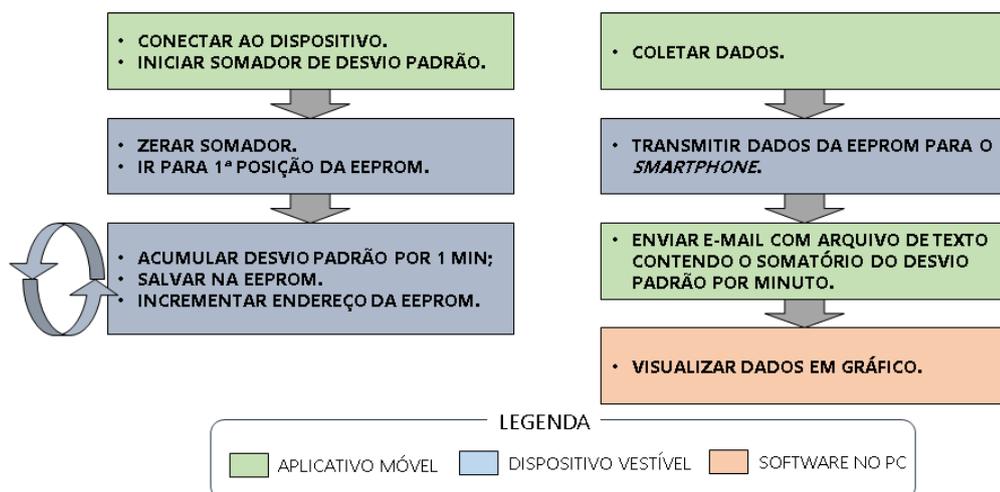


Figura 7 - Funcionamento da abordagem A₂.

Essa abordagem é a base de um sistema de monitoramento de pessoas com TAB, em desenvolvimento no NTA-UFES, pois é capaz de monitorar continuamente o nível

de atividade do paciente e contribuir para a identificação precoce de uma possível crise de depressão ou mania. O nível de atividade, representado pelo desvio padrão médio, a cada minuto, pode ser visualizado de forma gráfica pelo médico do paciente. Este, por sua vez, conhecendo seu paciente, pode reconhecer alterações, diminuição ou aumento de atividade física, e correlacioná-los com condições de humor relatadas pelo paciente.

4.1.3. Abordagem A₃ – Contador de passos

Na abordagem A₃, o dispositivo é utilizado na cintura do usuário, como um cinto, e o algoritmo embarcado no dispositivo vestível trata-se de um contador de passos. A contagem de passos funciona bem com o dispositivo nesta localização, pelo fato do acelerômetro se localizar em uma posição próxima ao centro de massa do corpo, e ser mais estável do que quando nas extremidades (CORNACCHIA et al., 2016). Entretanto, nesse caso, o dispositivo utilizado como um cinto pode não ser muito confortável, e o monitoramento do sono fica comprometido, visto que não é agradável dormir com um cinto e um dispositivo junto a seu corpo nessa região. O funcionamento dessa abordagem é semelhante ao da abordagem A₂ e pode ser observado na Figura 8.

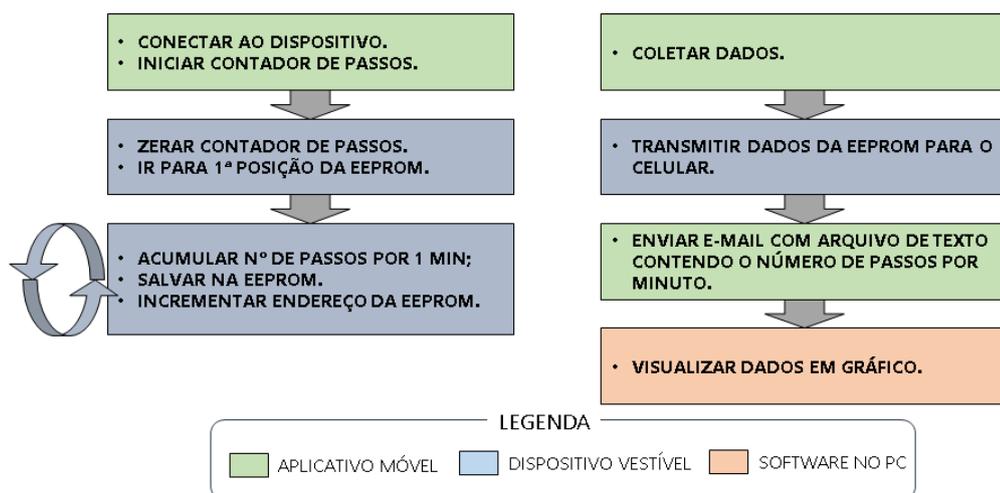


Figura 8 - Funcionamento da abordagem A₃.

Um algoritmo contador de passos é bastante comum em *smartphones* e pulseiras digitais, e é utilizado geralmente para monitorar a intensidade da atividade física

praticada por uma pessoa, ou medir a distância percorrida em determinado deslocamento. No caso deste trabalho, o número de passos coletados ao longo do dia pelo dispositivo pode ser transmitido para um e-mail para acompanhamento remoto. Pretende-se utilizar esse algoritmo como ferramenta auxiliar, tanto na aplicação de acompanhamento e prevenção de doenças crônicas, como em monitoramento de TAB.

4.2. HARDWARE

Esta seção apresenta o *hardware* desenvolvido para o dispositivo vestível utilizado nas três abordagens do sistema proposto. O diagrama da Figura 9 apresenta os principais componentes do dispositivo e como estes se relacionam. O acelerômetro coleta os dados e os transfere para o microcontrolador, no qual se executa o processamento das informações, que são enviadas para o *smartphone* do usuário por meio do módulo BLE. Cada parte componente do circuito eletrônico do *hardware* desenvolvido é apresentado na sequência.

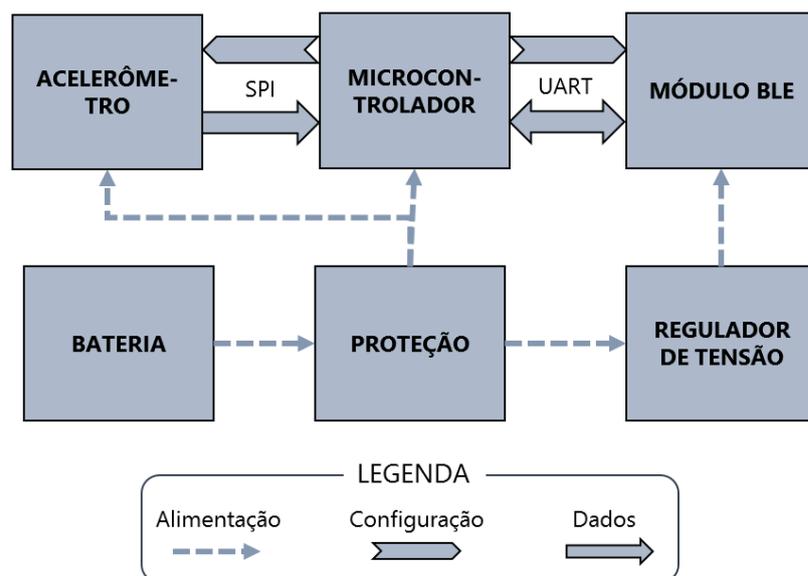


Figura 9 - Diagrama do *hardware* do dispositivo vestível desenvolvido.

4.2.1. Alimentação e proteção

Uma bateria de 3 V deve ser utilizada para alimentar o circuito, e um MOSFET canal P protege o circuito contra inserção de bateria com polaridade invertida, como mostra a Figura 10. Ao se alimentar corretamente o dispositivo, o diodo interno do MOSFET permite fluxo de corrente até a fonte (*source*) deste, e neste momento a tensão V_{GS} (*gate-source*) é igual a $-3V$ mais a queda de tensão no diodo, resultando em aproximadamente $-2,5V$. Visto que a condição para condução é V_{GS} menor que $-0,5V$, o MOSFET permite o fluxo de corrente com uma resistência entre dreno e fonte, R_{DS} (*drain-source*), em torno $0,06 \Omega$, segundo o *datasheet*, implicando uma queda de tensão praticamente nula para a corrente consumida pelo circuito.

No caso de inserção da bateria com polaridade invertida, o diodo interno do MOSFET não conduz, e a tensão V_{GS} neste caso é igual a $3V$, e assim o MOSFET bloqueia a corrente, impedindo-a de fluir para o circuito, e protegendo os componentes de alimentação invertida.

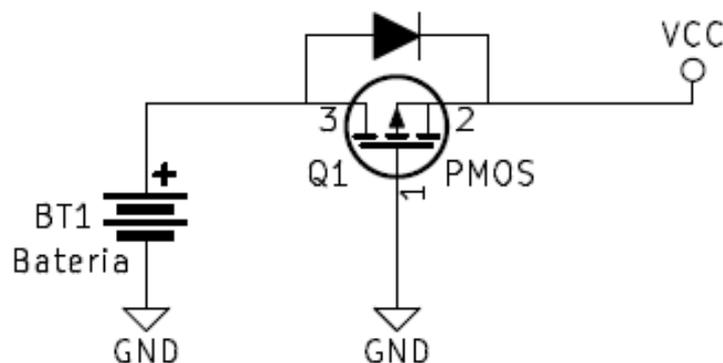


Figura 10 - Esquemático do circuito de alimentação e de proteção.

Durante os testes, o protótipo desenvolvido foi alimentado por uma bateria modelo CR2032, que tem capacidade em torno de 240 mAh para uma corrente de descarga de 0,3 mA, no entanto, essa capacidade se reduz para 170 mAh para uma corrente de 3 mA. Entretanto, esta bateria não se mostrou adequada para uso contínuo neste projeto, dadas as características do dispositivo neste primeiro protótipo. Apesar dos esforços empregados buscando baixo consumo energético, a corrente média

consumida pelo circuito durante os testes foi de 10 mA, o que implica em autonomia de menos de 12 horas para o *hardware* desenvolvido.

Portanto, a próxima versão do protótipo deve prever alimentação com uma bateria de capacidade superior, e, se necessário, com a possibilidade de recarga. Além disso, deve-se buscar uma redução ainda maior do consumo, investigando detalhadamente os pontos mais críticos no *firmware* e no circuito eletrônico.

4.2.2. Microcontrolador

O microcontrolador ATmega328P foi escolhido para este trabalho por ter características de baixo consumo energético e periféricos suficientes para atender às demandas do dispositivo. O ATmega328P é um microcontrolador de 8 bits, com 32 KB de memória flash programável, 1 KB de EEPROM, e 2 KB de memória SRAM. Entre os periféricos utilizados neste protótipo, o ATmega328P conta com *Universal Synchronous/Asynchronous Receiver/Transmitter (USART)*, *Serial Peripheral Interface (SPI)*, e três *timers*, além de fontes de interrupção interna e externa. O microcontrolador escolhido tem 32 pinos, pode operar na faixa de tensão de 1,8 a 5,5 V e com frequência de até 20 MHz. Optou-se pelo encapsulamento 32-TQFP, mostrado na Figura 11.

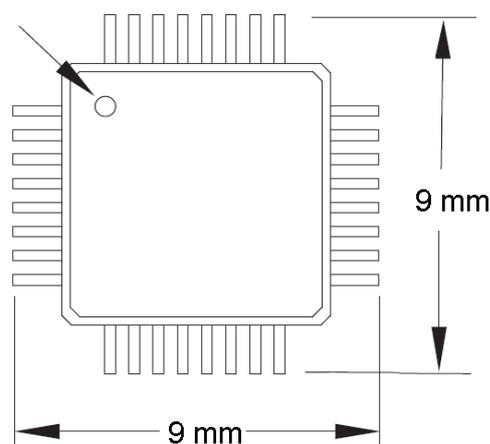


Figura 11 - Desenho do microcontrolador ATmega328p.

Fonte: Atmel, 2017.

A Figura 12 apresenta o esquemático do microcontrolador com os componentes utilizados e as conexões com os demais componentes do dispositivo. Podem-se ver capacitores de desacoplamento para filtrar ruídos de alta frequência na alimentação, as conexões via SPI com o acelerômetro (pinos 14 a 17) e as conexões via USART assíncrona com o módulo BLE (pinos 30 e 31).

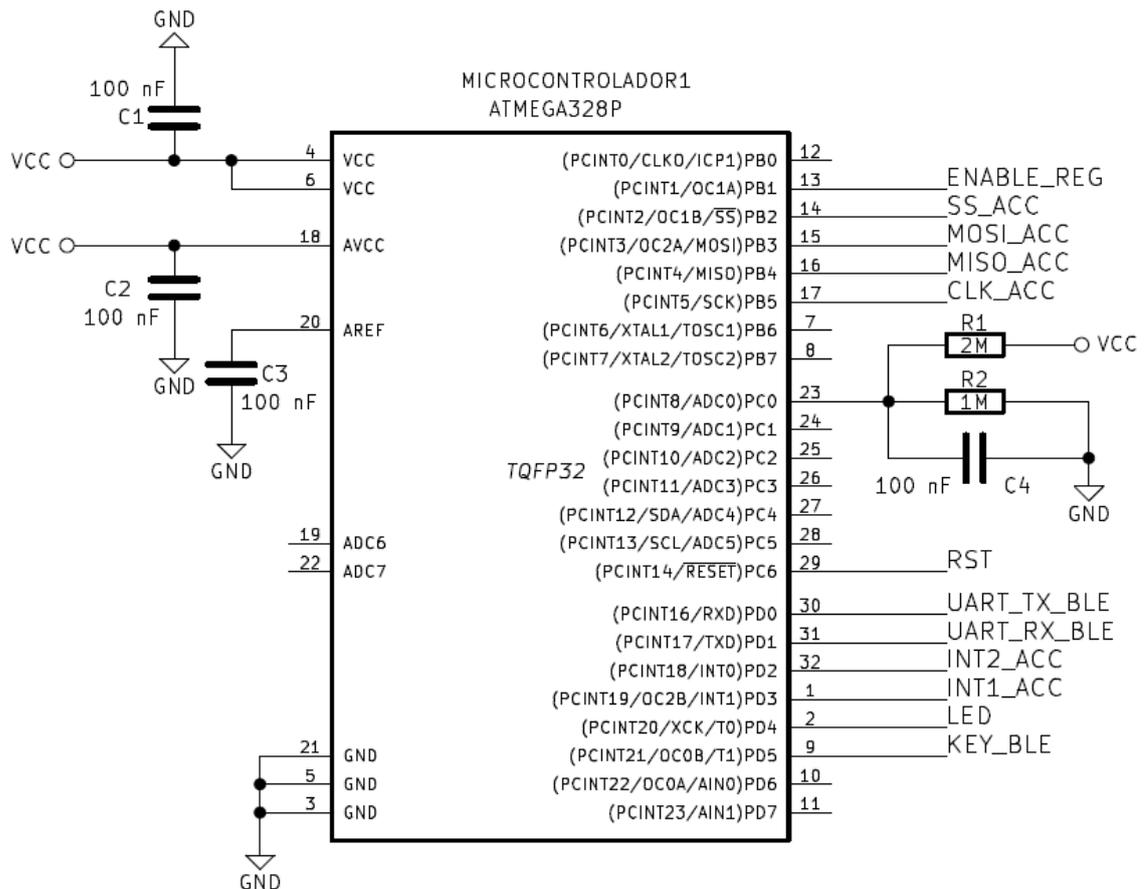


Figura 12 - Esquemático do microcontrolador.

4.2.3. Acelerômetro

O acelerômetro digital de três eixos utilizado é o ADXL362 da Analog Devices, que tem consumo energético bastante reduzido (*ultra low-power*) de apenas 2 μ A a uma taxa de 100 Hz de aquisição. Sua resolução é de 12 bits, tem faixa de medição programável de ± 2 , ± 4 e ± 8 g, e alimentação de 1,6 a 3,5 V. O ADXL362 possui internamente um filtro passa-baixas para *antialiasing*, configurável com frequência de corte em $\frac{1}{4}$ ou $\frac{1}{2}$ da frequência de aquisição. A comunicação com o microcontrolador

ocorre via SPI, e o acelerômetro opera como escravo. A Figura 13 apresenta o desenho com as dimensões do acelerômetro.

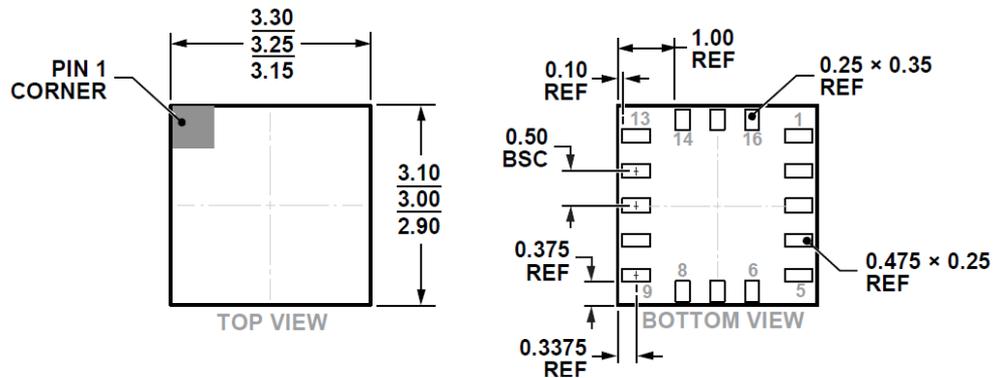


Figura 13 - Desenho e dimensões do acelerômetro ADXL362.

Fonte: Atmel, 2017.

A Figura 14 mostra o esquemático do acelerômetro e de suas conexões com o microcontrolador via SPI (pinos 4, 6, 7 e 8). Além disso, há dois pinos disponíveis (pinos 9 e 11) para trabalhar com interrupções geradas pelo acelerômetro, que não foram utilizadas neste protótipo. O acelerômetro, assim como o microcontrolador, é alimentado diretamente pela bateria.

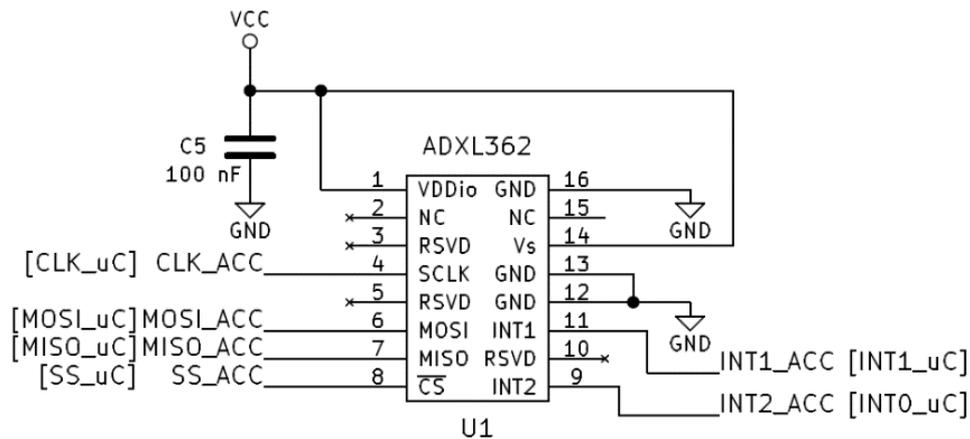


Figura 14 - Esquemático do acelerômetro.

4.2.4. Módulo Bluetooth Low Energy (BLE)

A escolha pela comunicação BLE ocorreu pelo seu baixo consumo energético, quando comparado com as tecnologias concorrentes, e pela disseminação desta tecnologia em dispositivos móveis como *smartphones* e *tablets*. Para implementar a

comunicação, optou-se pelo módulo HM-10 (Figura 15), um SoC que implementa a pilha do protocolo BLE em *hardware* e *firmware*, além de conter o circuito de radiofrequência, incluindo a antena, e o circuito de comunicação com um microcontrolador principal via serial UART.

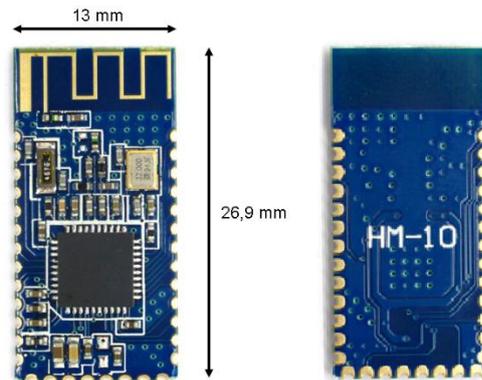


Figura 15 - Módulo HM-10 e dimensões.

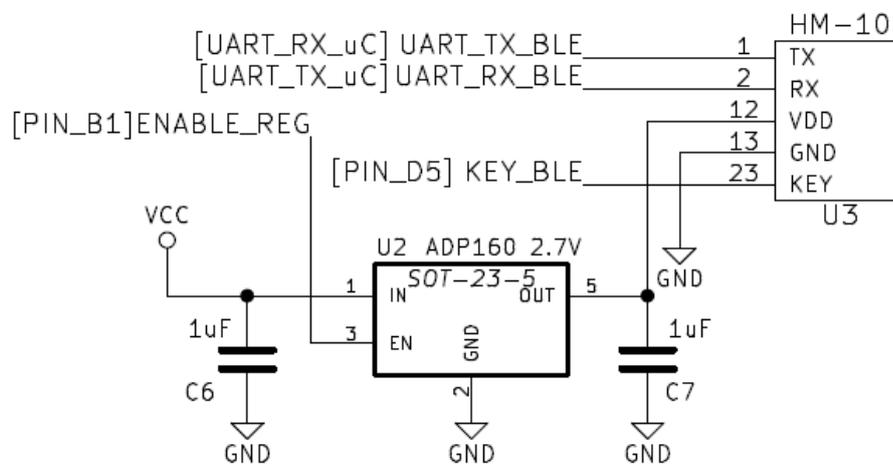


Figura 16 - Esquemático do módulo BLE.

Um regulador de tensão de 2,7 V, de baixa queda de tensão (*low-dropout regulator*) foi utilizado para o alimentar o HM-10 para o ligar apenas quando necessário, visto que este é o componente com maior consumo energético do circuito. No entanto, na configuração deste primeiro protótipo, o HM-10 foi mantido sempre ligado, pois o dispositivo pode receber comandos do *smartphone* via BLE a qualquer momento que o usuário desejar interagir. A Figura 16 apresenta o esquemático do regulador de tensão e do módulo HM-10 com suas conexões para comunicação via UART com o microcontrolador.

4.2.5. Placa de Circuito Impresso

A Placa de Circuito Impresso (PCI) com o circuito eletrônico desenvolvido foi projetada no *software* de código aberto (*open-source*) KiCad. A Figura 17a apresenta o *layout* da camada superior da PCI, indicando a posição dos principais componentes, enquanto a Figura 17b mostra o *layout* da camada inferior e a posição do módulo BLE. A Figura 18 mostra a PCI já fabricada e com os componentes soldados.

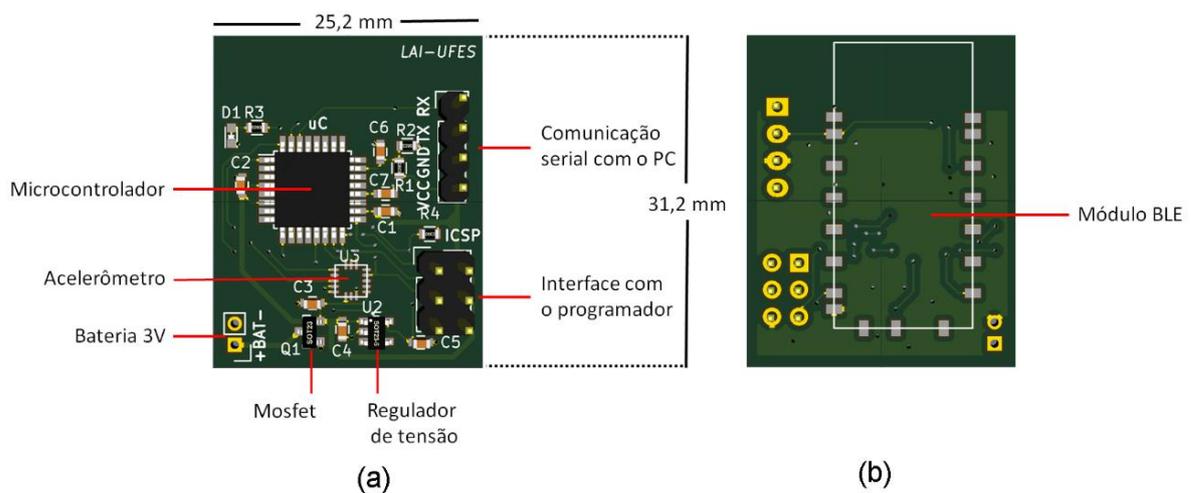


Figura 17 – *Layout* da PCI: a) camada superior; b) camada inferior.

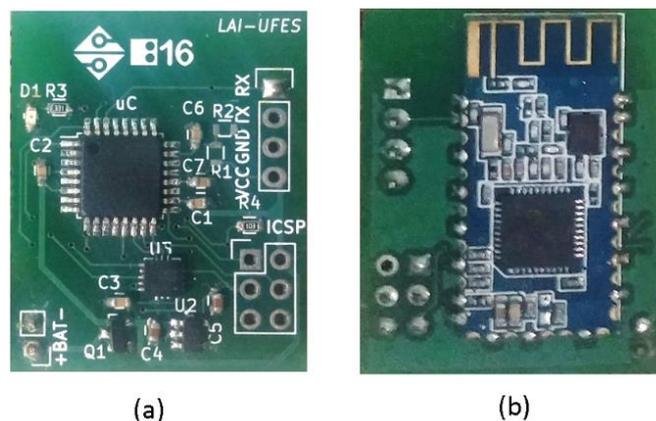


Figura 18 - PCI produzida: a) camada superior; b) camada inferior.

4.2.6. Protótipo

A PCI foi soldada sobre uma placa universal para incluir o suporte para a bateria CR2032 e uma chave para ligar e desligar o dispositivo. A placa universal foi acoplada

à base de uma caixa plástica com dimensões de 60 mm de profundidade, 35 mm de largura e 8 mm de altura. Um invólucro de borracha foi utilizado para encapsular esse conjunto. A Figura 19 mostra o conjunto placa universal e caixa plástica, e o encapsulamento, enquanto a Figura 20 apresenta o protótipo montado e suas dimensões.



Figura 19 - Partes do protótipo desenvolvido.



Figura 20 - Protótipo montado e suas dimensões.

O dispositivo protótipo desenvolvido pode ser vestido como um cinto, ou como uma pulseira, para atender às diferentes abordagens apresentadas anteriormente. A Figura 21a apresenta o dispositivo vestível utilizado como um cinto, enquanto a Figura 21b mostra o dispositivo utilizado como uma pulseira.

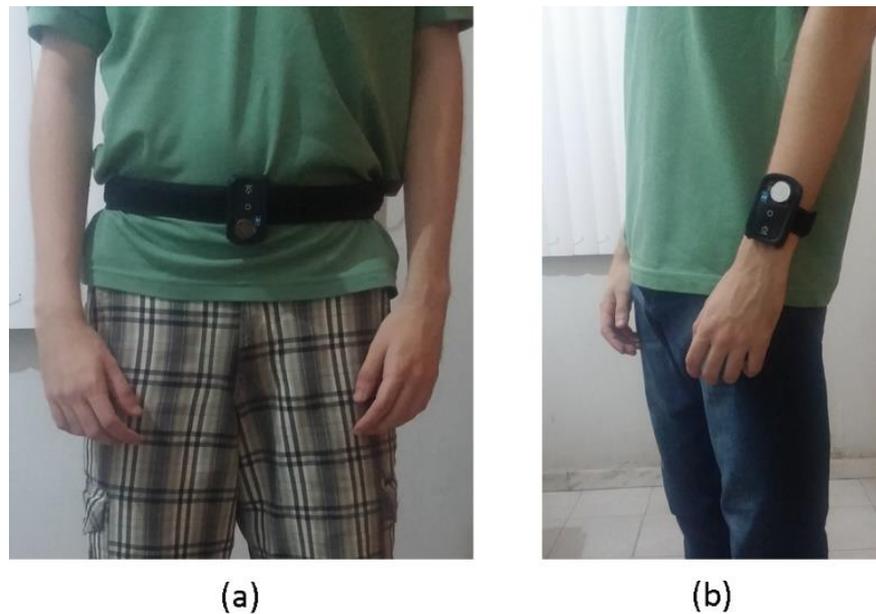


Figura 21 - Dispositivo vestível: a) como um cinto; b) como uma pulseira.

4.3. FIRMWARE

Esta seção aborda os três diferentes *firmwares* desenvolvidos, um para cada abordagem, e embarcados no microcontrolador do dispositivo vestível. Os programas foram desenvolvidos no ambiente de desenvolvimento Atmel Studio, *software* gratuito oferecido pelo fabricante do microcontrolador utilizado neste trabalho (Atmel).

Apresentam-se o algoritmo para configurar os parâmetros do microcontrolador e a comunicação deste com os demais componentes, e a lógica de programação de cada abordagem. As técnicas e os cálculos aplicados ao processo de HAR, ao desvio padrão médio e ao contador de passos são apresentados com mais detalhes no Capítulo 5.

O código de configuração é comum aos três programas, e é apresentado na Figura 22. O *clock* do processador é definido como 8 MHz, gerado internamente. Os dados lidos do acelerômetro são do tipo inteiro com sinal de 16 bits, enquanto os dados referentes aos parâmetros extraídos do sinal são do tipo ponto flutuante de precisão simples.

A USART, utilizada para comunicação serial com o módulo BLE HM-10, é configurada no modo assíncrono com taxa de transmissão de 9600 bit/s, e com interrupção

habilitada na recepção de dados, para tratar os comandos recebidos do *smartphone* via BLE. A SPI, usada para comunicação com o acelerômetro ADXL362, é configurada no modo mestre, com taxa de transferência de 2 MHz. O acelerômetro é configurado com faixa de medição de ± 4 g, frequência de leitura de 100 Hz e filtro *antialiasing* com frequência de corte em 25 Hz.

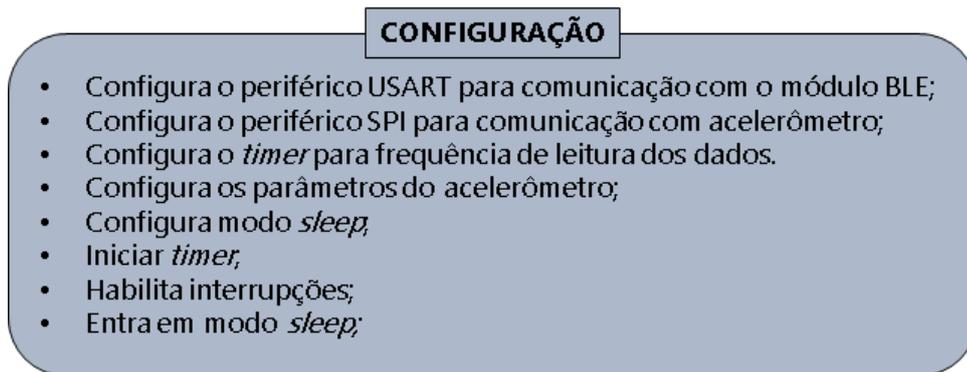


Figura 22 - Código de configuração dos *firmwares*.

O *timer 2* do microcontrolador é configurado para gerar uma interrupção a cada 10 ms, para que se executem leituras do acelerômetro a uma taxa de 100 Hz. Por fim, o *timer* é iniciado, as interrupções globais são habilitadas e o microcontrolador é colocado no modo *sleep*.

4.3.1. Algoritmo da abordagem A₁

O *firmware* de HAR, desenvolvido para a abordagem A₁, segmenta os dados coletados da aceleração dos eixos Y e Z em janelas de dois segundos, com um segundo de sobreposição, aplica a extração de características à janela e classifica a atividade realizada pelo usuário. Cada uma dessas etapas é explicada detalhadamente no Capítulo 5.

O funcionamento geral desse algoritmo apresenta-se na Figura 23, a qual mostra o código da rotina cíclica, da rotina gerada pela interrupção do *timer* e da rotina gerada por um dado recebido via USART. Os comandos enviados a partir do *smartphone* para iniciar e terminar a operação são recebidos pelo módulo BLE e, via USART, pelo microcontrolador, e são responsáveis por, respectivamente, ativar e desativar o *timer*. Além disso, o comando recebido referente à calibração executa na rotina principal o

cálculo do *offset* de cada eixo, para posteriormente ajustar os valores, visando atenuar os efeitos do posicionamento diferente do dispositivo, em cada usuário, devido às diferenças de características físicas e da própria instalação no corpo.

Quando ativado, o *timer* gera interrupções a uma taxa de 100 Hz para leitura do acelerômetro. Os dados coletados a 100 Hz são filtrados com aplicação de média aritmética simples a cada 10 amostras, resultando na aquisição de um sinal suavizado à taxa de 10 Hz. A média resultante é adicionada a uma janela, que acumula dados por dois segundos. Quando a janela está completa, a extração de características é ativada. Na rotina principal, aplica-se a extração de características e, na sequência, o classificador. Por fim, a atividade identificada é transmitida via USART para o módulo BLE e deste para o *smartphone*. Após um segundo, a janela de dados estará completa novamente, e o processo é repetido com uma nova atividade reconhecida e enviada para o *smartphone*.

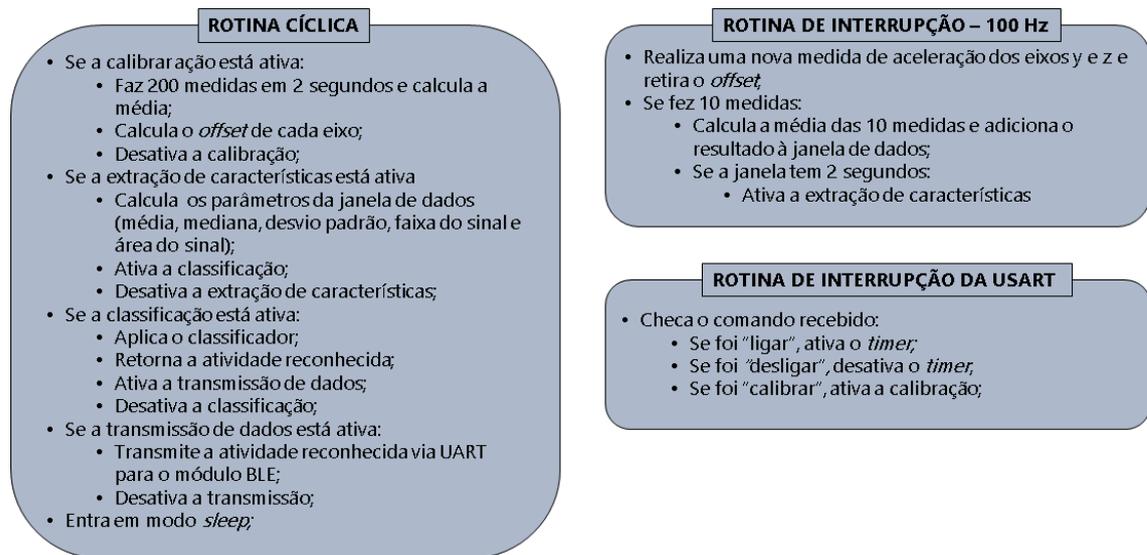


Figura 23 - Algoritmo do sistema de HAR.

4.3.2. Algoritmo da abordagem A₂

Este algoritmo calcula o desvio padrão de uma janela de um segundo de dados do módulo da aceleração resultante dos três eixos, e foi desenvolvido para atender à abordagem A₂. A Figura 24 apresenta o diagrama do *firmware* desenvolvido. Quando a coleta de dados é iniciada ou finalizada pelo usuário no *smartphone*, um comando

é enviado via BLE para o dispositivo, e o microcontrolador recebe este comando via USART, por meio do módulo BLE, e executa ou termina a operação.

Assim que se inicia a coleta, o somatório do desvio padrão é zerado e o ponteiro da EEPROM vai para a primeira posição. A aquisição da aceleração dos três eixos ocorre à taxa de 100 Hz, aplicando-se média aritmética a cada 10 amostras. Calcula-se o módulo resultante da média da aceleração dos três eixos e o valor obtido é adicionado a uma janela de dados. Assim que a janela acumula um segundo de informação, o cálculo do desvio padrão é ativado para ser executado na rotina principal. Calcula-se, então, o desvio padrão da janela de dados, e o resultado é adicionado ao somatório. Quando se acumula o desvio padrão por um minuto, divide-se o somatório por 60 e se obtém a média do desvio padrão, a qual é armazenada na EEPROM, e o ponteiro desta é incrementado para o próximo endereço. Assim que se finaliza a coleta, os dados guardados na EEPROM são enviados via USART para o módulo BLE, e deste para o *smartphone*.

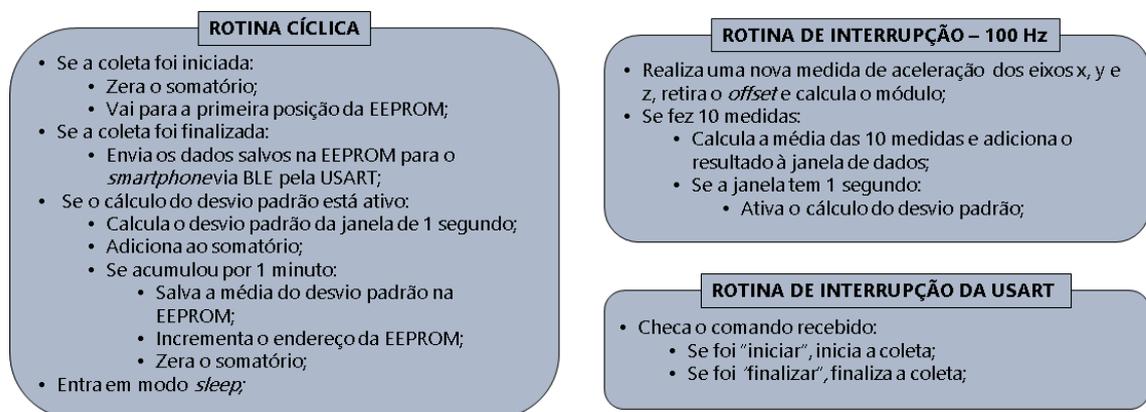


Figura 24 - Algoritmo responsável pelo cálculo e pelo armazenamento do desvio padrão da aceleração.

4.3.3. Algoritmo da abordagem A₃

O *firmware* contador de passos foi implementado para a abordagem A₃, e seu ciclo de operação pode ser observado na Figura 25. O início e o fim da coleta ocorrem igualmente ao algoritmo do desvio padrão médio, recebendo comandos do *smartphone* via USART por intermédio do módulo BLE.

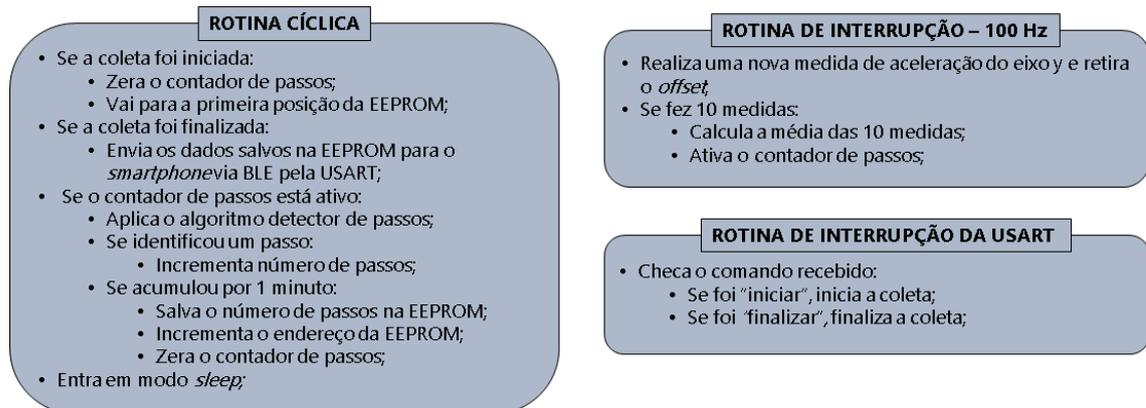


Figura 25 - Algoritmo contador de passos.

Quando a coleta é iniciada, o contador de passos é zerado e o ponteiro da EEPROM vai para a primeira posição. A aquisição ocorre igualmente aos casos anteriores, com taxa de 100 Hz e média aritmética a cada 10 amostras, porém, no caso, apenas da aceleração do eixo Y. Assim que a média é calculada, o contador de passos é ativado para ser executado na rotina principal. Executa-se, então, o contador de passos e, caso seja detectado um passo, incrementa-se o valor atual. Caso tenha acumulado o número de passos por um minuto, o somatório é salvo na EEPROM e o ponteiro desta é incrementado para o próximo endereço. Quando a coleta é finalizada, os dados salvos na EEPROM são enviados via USART para o módulo BLE e deste para o *smartphone*.

4.4. APLICATIVO MÓVEL

Um aplicativo móvel para *smartphone* foi desenvolvido para atuar como acumulador local no sistema vestível de monitoramento remoto proposto neste trabalho. O aplicativo foi implementado para o sistema operacional Android no ambiente de desenvolvimento Android Studio. A principal função do aplicativo móvel é coletar os dados enviados pelo dispositivo vestível via BLE, e transferi-los, por e-mail, para monitoramento remoto. Além disso, o aplicativo permite que o usuário interaja com o dispositivo, ligando e desligando a coleta de dados, e visualizando as informações coletadas.

Visando atender às três abordagens desenvolvidas neste trabalho, foram implementados três diferentes aplicativos, que são apresentados na sequência.

Utilizou-se como código base um programa exemplo referente à implementação da comunicação BLE, disponibilizado pelo *Android Developers*. A primeira tela do aplicativo é comum nas três abordagens e apresenta-se na Figura 26. Assim que o usuário executa o aplicativo, o Bluetooth do *smartphone* é ativado, e uma lista com os dispositivos BLE próximos é apresentada. O usuário deve escolher o dispositivo “HMSoft” para se conectar ao dispositivo vestível. Assim que a conexão for estabelecida, apresenta-se uma nova tela, de acordo com a abordagem.

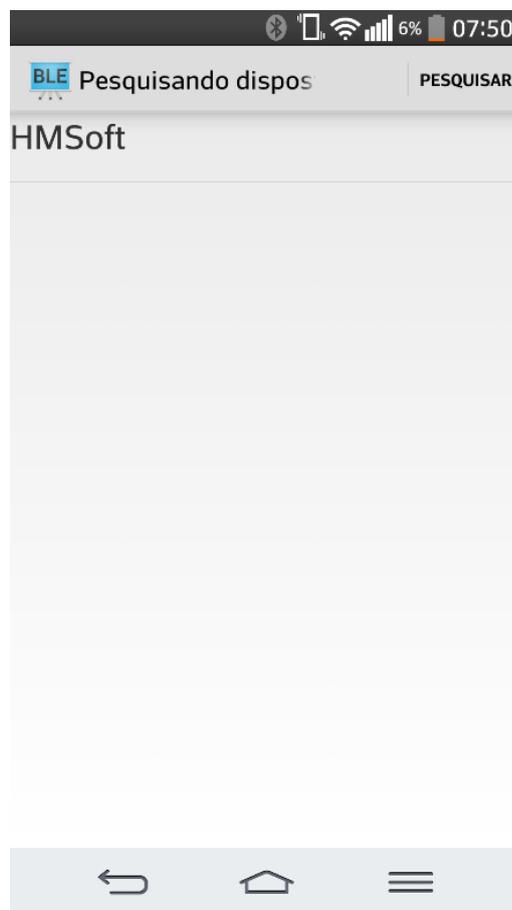


Figura 26 - Tela inicial do aplicativo móvel.

4.4.1. Aplicativo móvel da abordagem A₁

Na primeira abordagem, o aplicativo permite o usuário iniciar e finalizar a classificação de atividades realizada pelo dispositivo vestível. Previamente à operação do sistema, pede-se que o usuário se coloque de pé em posição ereta e execute a opção “calibrar” no aplicativo móvel. Assim, que a operação é iniciada, o usuário recebe, via BLE, a

atividade reconhecida a cada um segundo, e esta é apresentada na tela do *smartphone*. A Figura 27 mostra a o aplicativo em operação e a apresentação da atividade reconhecida.

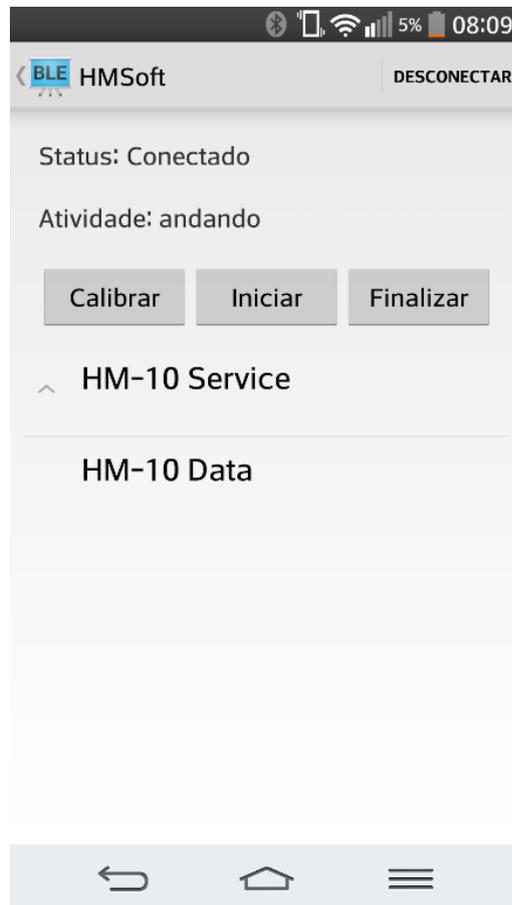


Figura 27 - Tela de operação do aplicativo móvel da abordagem A₁.

4.4.2. Aplicativo móvel da abordagem A₂

A Figura 28a apresenta o aplicativo desenvolvido para a abordagem A₂, o qual contém opções para iniciar e finalizar a coleta de dados, e campos para inserção do nome do usuário e do e-mail para o qual as informações coletadas são enviadas. Já a Figura 28b mostra a mensagem de confirmação para transferência dos dados coletados por e-mail.

O usuário deve escolher a opção “iniciar coleta” para começar a aquisição de dados de aceleração e armazenamento do desvio padrão pelo dispositivo vestível. O aplicativo, então, pode ser fechado, e o dispositivo coletará os dados ao longo do dia

sem a necessidade do *smartphone* por perto. Quando desejado, o usuário pode concluir a coleta, escolhendo a opção “finalizar coleta” no aplicativo. Neste momento, os dados armazenados durante o dia no dispositivo vestível são transferidos, via BLE, para o *smartphone*, salvos em um arquivo de texto, e enviados para o e-mail cadastrado, se o usuário aceitar.

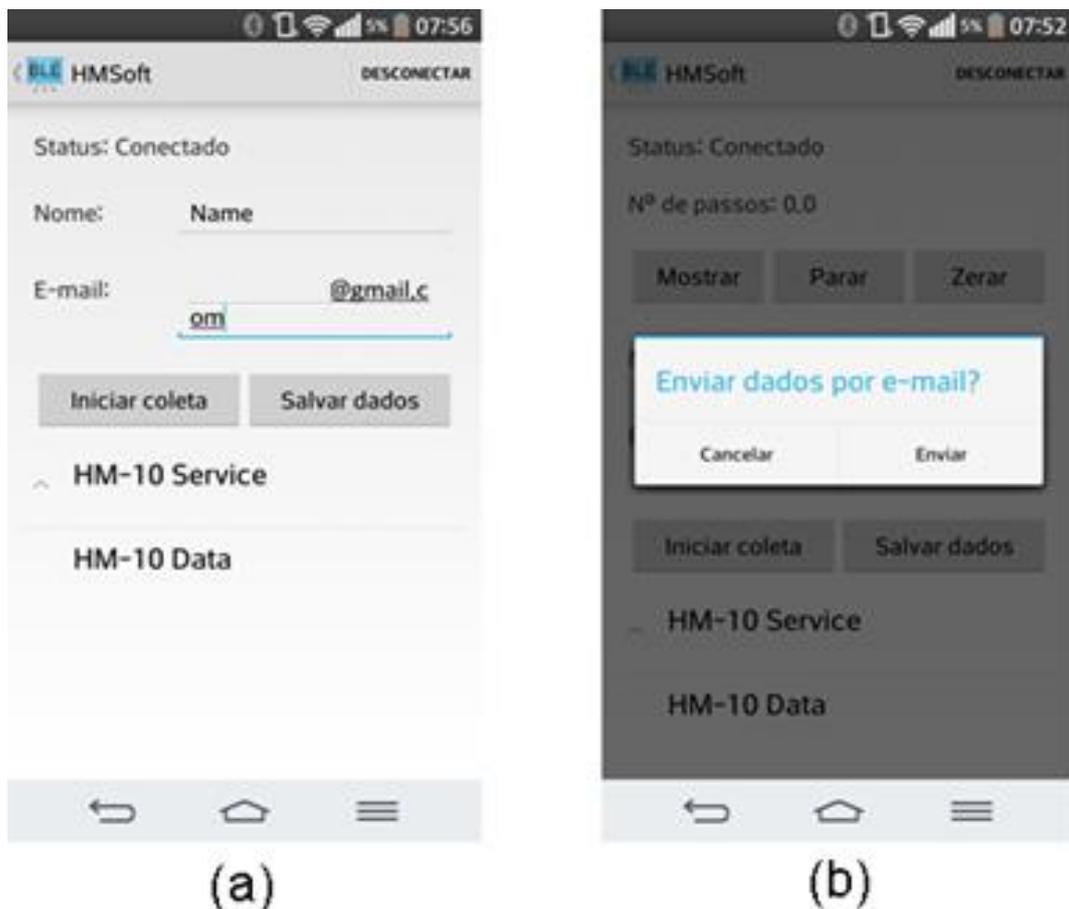


Figura 28 - Aplicativo móvel da abordagem A₂: a) tela de operação; b) confirmação de envio de dados por e-mail.

4.4.3. Aplicativo móvel da abordagem A₃

O aplicativo desenvolvido para a abordagem A₃ pode ser observado na Figura 29. O início e a finalização da coleta de dados funcionam de maneira semelhante ao aplicativo da abordagem A₂. Adicionalmente, neste aplicativo o usuário pode visualizar, na tela do *smartphone*, o número total de passos executados, sempre que

desejar, e também pode zerar a contagem global, sem afetar o valor coletado para monitoramento remoto.

Para análise dos dados coletados, foi desenvolvido neste trabalho um *software* no Matlab, no qual o arquivo de texto “.txt” com os dados coletados, gerado pelo *smartphone*, é enviado para o e-mail do profissional responsável pela análise dos dados. O arquivo recebido deve ser executado pelo *software* para visualização dos dados coletados ao longo do dia.



Figura 29 - Tela de operação do aplicativo móvel da abordagem A₃.

4.5. APLICAÇÃO PARA ANÁLISE DOS DADOS

Assim que o *software* abre o arquivo de texto, e o profissional escolhe a opção “visualizar”, os dados são apresentados em forma de gráfico, com o parâmetro medido a cada minuto durante a coleta. Além disso, são apresentadas informações como nome do usuário (paciente), a data e os horários de início e fim da coleta. Também há

opções para modificar o intervalo de apresentação do parâmetro no gráfico: por minuto, por 15 minutos, por 30 minutos ou por hora. Como exemplo, a Figura 30 mostra uma imagem do *software* apresentando informações de uma coleta com o número de passos executados por minuto, durante, aproximadamente, uma hora e trinta minutos.

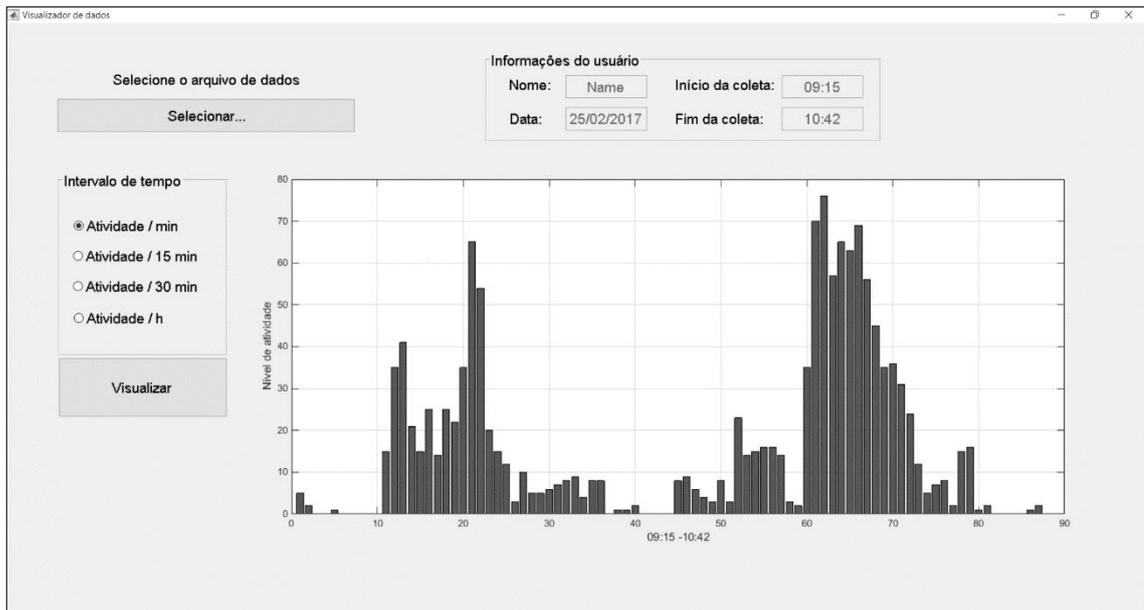


Figura 30 - Aplicação para visualização dos dados coletados.

5. PROCESSAMENTO DOS DADOS

Este capítulo apresenta o processo de HAR, desenvolvido para a abordagem A_1 , o procedimento de monitoramento do desvio padrão, implementado para a abordagem A_2 , e a construção do contador de passos, elaborado para a abordagem A_3 . Também são apresentadas as justificativas para a escolha dos parâmetros utilizados nas técnicas e cálculos em cada abordagem.

5.1. AQUISIÇÃO DOS DADOS

As características do dispositivo vestível desenvolvido exigiram a opção por um microcontrolador considerado simples, de baixo consumo energético, e de baixo custo. Em contrapartida, surgem algumas desvantagens a esse respeito, como os recursos limitados de memória, de velocidade de processamento e de operações matemáticas com ponto flutuante. Dados os requisitos de baixo consumo energético, e as limitações do microcontrolador escolhido (ATmega328P), adotou-se uma configuração que contribui para um consumo energético reduzido, sem prejudicar o bom funcionamento do processo.

Ao se escolher a taxa de amostragem, buscou-se um valor eficiente para o processo de reconhecimento desenvolvido, sabendo-se que quanto menor a taxa, menor o consumo energético, visto que o microcontrolador teria que “despertar” menos vezes para realizar operações. De acordo com Gao, Bourke e Nelson (2014), uma taxa de amostragem do sinal de aceleração a partir de 10 Hz mostra-se eficiente em sistemas de HAR.

Portanto, optou-se, no presente trabalho, por uma taxa de aquisição de dados do acelerômetro de 100 Hz, porém, com a aplicação de média aritmética simples a cada 10 amostras, resultando em um sinal coletado a 10 Hz, do ponto de vista das próximas etapas do sistema. Dessa forma, obtém-se um sinal suavizado, com variância reduzida, sem perda de informações importantes no contexto de HAR. A aquisição dos dados ocorre da mesma maneira nas três abordagens, que são apresentadas na sequência.

5.2. PROCESSO DE RECONHECIMENTO DE ATIVIDADES HUMANAS

O sistema de HAR desenvolvido neste trabalho tem como objetivo identificar a atividade que está sendo realizada pelo usuário, entre seis possíveis, sendo quatro delas dinâmicas – “andando”, “correndo”, “subindo escadas” e “descendo escadas” – e duas estáticas – “em pé” e “sentado”. Optou-se por atividades comuns do dia-a-dia e bastante utilizadas nas propostas recentes neste contexto. Na abordagem desenvolvida para validação do sistema, a atividade reconhecida é enviada para o *smartphone* do usuário para apresentação da informação.

No sistema de HAR implementado neste trabalho para a abordagem A₁, o dispositivo vestível é utilizado na altura da cintura do usuário, como já apresentado na Figura 21a. A localização e a orientação do acelerômetro do dispositivo em relação aos eixos do corpo humano são mostradas na Figura 31. Pode-se observar que, neste caso, quando o indivíduo se encontra em pé, o eixo Y do acelerômetro se orienta aproximadamente na direção da aceleração da gravidade.

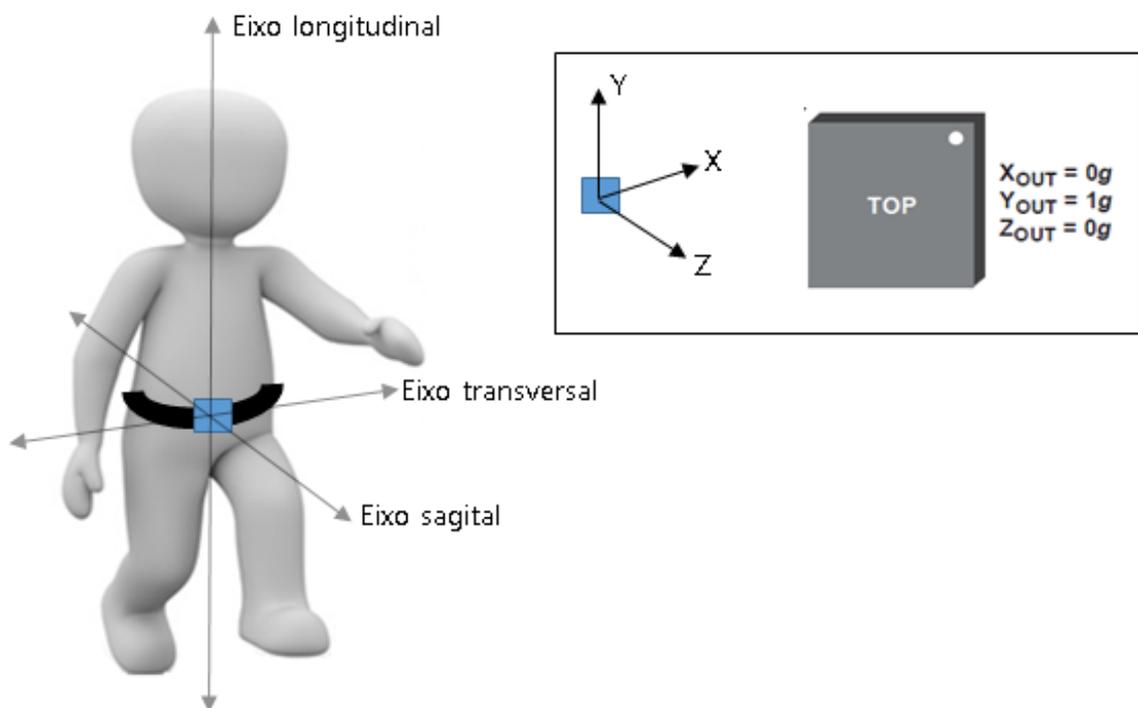


Figura 31 – Orientação do acelerômetro em relação ao corpo do indivíduo.

Dados os recursos disponíveis no microcontrolador relativos à capacidade de memória volátil, foi necessário reduzir o volume de dados utilizados no processo de HAR desenvolvido. Portanto, optou-se por dispensar os sinais de um dos eixos do acelerômetro. Assim, para encontrar o eixo que contém informações com menor variação entre as diferentes atividades reconhecidas pelo sistema, foi realizado um teste preliminar utilizando os sinais dos três eixos, no qual se avaliou o desvio absoluto médio entre as características extraídas de cada eixo.

Nesse teste, pediu-se que um indivíduo realizasse as quatro atividades dinâmicas que se desejam reconhecer pelo classificador, utilizando o dispositivo vestível na cintura, e com os dados sendo coletados e armazenados por um *smartphone*. Posteriormente, os dados de aceleração dos três eixos foram transferidos para um computador para análise. Para realizar a análise, calcularam-se e normalizaram-se os atributos – média, desvio padrão, mediana, faixa do sinal e SMA – que são utilizados na etapa de extração de características, descrita mais adiante na Seção 5.2.2. As atividades estáticas – “andando” e “em pé” – não foram analisadas neste caso, pois dependem apenas do valor médio da aceleração, e podem ser mais facilmente identificadas.

Em um processo de classificação de padrões, é importante que os diferentes atributos apresentem variabilidade entre si, de forma a contribuir para um bom desempenho do classificador. Por essa razão, computou-se, para cada atributo e para cada eixo, o desvio percentual entre atividades diferentes, fazendo combinações de duas em duas, e calculou-se a média. A Tabela 3 mostra os resultados.

Nota-se que os parâmetros extraídos do eixo Z mostraram maior desvio entre as atividades realizadas, indicando que esse eixo tem importante relevância no processo de classificação. O menor desvio percentual médio foi apresentado pelo eixo X, e, portanto, optou-se por dispensá-lo do processo de HAR desenvolvido neste trabalho. Assim, decidiu-se trabalhar, nesta abordagem A_1 do sistema, com os eixos Y e Z do acelerômetro, associados, respectivamente, aos eixos longitudinal e sagital, do corpo humano, dada a orientação do dispositivo.

Tabela 3 - Desvio percentual dos atributos entre as atividades

Atributos	Desvio percentual médio		
	Eixo X	Eixo Y	Eixo Z
Média	18,14%	5,67%	96,20%
Desvio padrão	15,26%	44,70%	23,23%
Mediana	18,95%	8,51%	161,21%
Faixa do sinal	26,32%	39,59%	31,82%
SMA	39,96%	63,65%	44,98%
Média dos atributos	23,73%	32,42%	71,49%

Um exemplo de dados de aceleração coletados pelo dispositivo desenvolvido, com uma pessoa o utilizando como um cinto ao caminhar, é mostrado na Figura 32. O gráfico apresenta o valor da aceleração em mg ($10^{-3}g$), sendo g o valor da aceleração gravitacional. Nota-se que o valor da aceleração do eixo Y (eixo longitudinal do corpo humano) varia, aproximadamente, em torno de 1000 mg ($\approx 9,8 \text{ m/s}^2$), quando o usuário está caminhando.

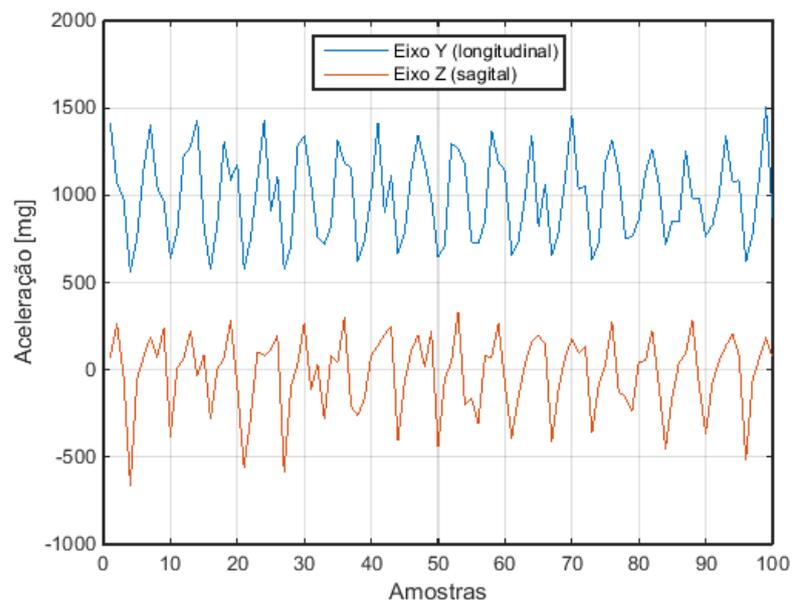


Figura 32 - Exemplo de dados de aceleração coletados.

5.2.1. Segmentação

A segmentação tem o papel de separar o conjunto de dados a ser aplicado nas próximas etapas do processo de HAR. Da forma como foi descrito anteriormente, a aquisição de dados ocorre a 100 Hz, com a média aritmética aplicada a cada 10 amostras sobre os valores de aceleração coletados dos eixos Y e Z, como mostram as Equações 4 e 5, sendo n uma leitura a 100 Hz, e i uma leitura média a 10 Hz.

$$\bar{a}_{y,i} = \frac{1}{10} \sum_{n=1}^{10} a_{y,n} \quad (4)$$

$$\bar{a}_{z,i} = \frac{1}{10} \sum_{n=1}^{10} a_{z,n} \quad (5)$$

A escolha de uma taxa de aquisição reduzida – 10 Hz após a aplicação da média – também foi importante para a segmentação, pois essa etapa acumula os sinais coletados em uma janela de dados. Ou seja, uma janela com mesmo tamanho temporal apresenta 10 vezes menos elementos com uma taxa de aquisição de 10 Hz em relação a uma taxa de 100 Hz, contribuindo para uma redução drástica de uso de memória de dados, recurso limitado do microcontrolador.

A escolha do tamanho da janela de dados deve levar em consideração os tipos de atividades a serem classificadas e o processamento computacional disponível, visto que atividades consideradas complexas, por não serem cíclicas, exigem uma janela maior, e, conseqüentemente, maior custo computacional. No caso deste trabalho, as atividades dinâmicas que se desejam classificar têm características de periodicidade, e, por isso, podem ser identificadas com uma janela de dados menor.

Com o objetivo de definir o tamanho da janela de dados utilizada no sistema proposto, analisaram-se as propostas recentes de sistemas de HAR, as quais obtiveram bons resultados na classificação de atividades semelhantes às que se desejam classificar neste trabalho (PAUL; GEORGE, 2015; LUBINA; RUDZKI, 2015; MUÑOZ-ORGANERO; LOFTI, 2016). Concluiu-se, então, que uma janela de dois segundos representa uma boa relação entre quantidade de informação e custo computacional.

Para construir uma janela de dois segundos com as médias calculadas a 10 Hz, devem-se acumular 20 amostras das médias, como mostram as Equações 6 e 7, sendo \mathbf{w} o vetor de elementos que formam a janela. Neste sistema, definiu-se trabalhar com sobreposição de 50% da janela, ou seja, um segundo, para que se obtenha um novo resultado de classificação a cada um segundo. A Figura 33 mostra um exemplo de segmentação das primeiras três janelas, com 50% de sobreposição, de uma série de dados de aceleração dos eixos Y e Z.

$$\mathbf{w}_y = [\bar{a}_{y,1}, \bar{a}_{y,2}, \bar{a}_{y,3}, \dots, \bar{a}_{y,20}] \quad (6)$$

$$\mathbf{w}_z = [\bar{a}_{z,1}, \bar{a}_{z,2}, \bar{a}_{z,3}, \dots, \bar{a}_{z,20}] \quad (7)$$

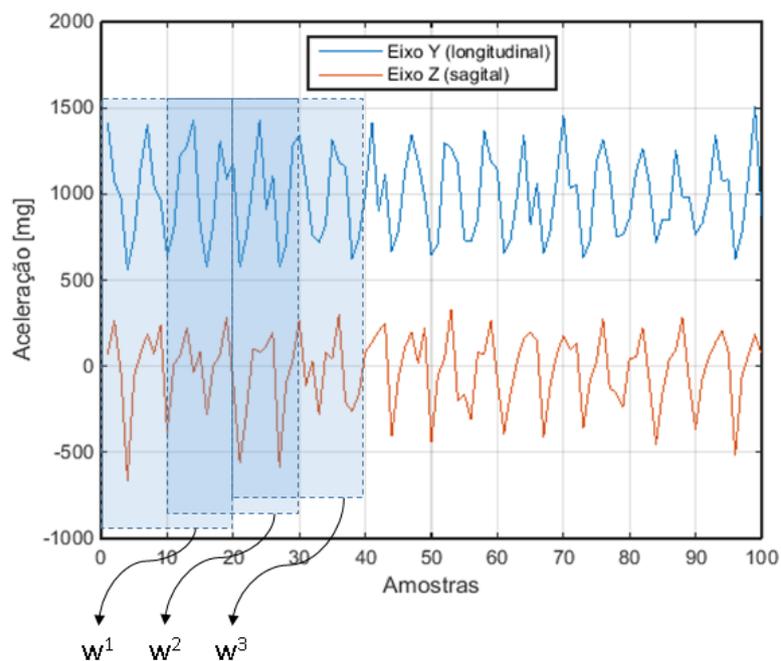


Figura 33 - Exemplo da segmentação dos dados.

5.2.2. Extração e seleção de características

A função da extração de características é extrair as características mais relevantes da janela de dados, formando um conjunto reduzido em relação ao conjunto original, mas capaz de representar o padrão executado. Como abordado, na Seção 3.2.4, a extração de características em sistemas de HAR pode adotar parâmetros do domínio do tempo e da frequência. Neste trabalho, visto que o sistema de classificação se encontra embarcado no dispositivo vestível, buscou-se trabalhar com aquelas características que são calculadas mais rapidamente pelo processador.

Portanto, optou-se por características do domínio do tempo, visto que atributos do domínio da frequência exigem a aplicação de técnicas como a transformada de Fourier, as quais exigem maior custo computacional para o microcontrolador. Assim, as características utilizadas no sistema proposto neste trabalho são: média, desvio padrão, mediana, faixa do sinal e SMA. Cada um desses atributos é calculado sobre as janelas de dados \mathbf{w}_y e \mathbf{w}_z , obtidas da etapa de segmentação.

A média μ , o desvio padrão σ , a faixa do sinal r , e a SMA, calculados sobre as janelas de dados, são definidos, respectivamente, pelas Equações 8, 9, 10, e 11, sendo e o eixo Y ou Z, e $\bar{a}_{e,m}$ cada elemento que compõe a janela \mathbf{w}_e . A mediana é definida por m , e trata-se do elemento central que separa o conjunto de dados em dois grupos.

$$\mu_e = \frac{1}{20} \sum_{m=1}^{20} \bar{a}_{e,m} \quad (8)$$

$$\sigma_e = \sqrt{\frac{1}{20} \sum_{m=1}^{20} (\bar{a}_{e,m} - \mu_e)^2} \quad (9)$$

$$r_e = \max(\mathbf{w}_e) - \min(\mathbf{w}_e) \quad (10)$$

$$sma_e = \sum_{m=1}^{20} |\bar{a}_{e,m}| \quad (11)$$

As características, ou atributos, extraídas das janelas de dados formam o vetor de características, que será aplicado à entrada do algoritmo classificador. Como foram extraídos cinco atributos do eixo Y e outros cinco do eixo Z, obtiveram-se, no total, 10 atributos como vetor de características, definido pela Equação 12.

$$v = [\mu_y, \mu_z, \sigma_y, \sigma_z, m_y, m_z, r_y, r_z, sma_y, sma_z] \quad (12)$$

Alternativamente ou adicionalmente ao processo de extração de características, pode-se aplicar uma técnica de seleção de atributos para escolher, baseado em uma métrica, aqueles mais relevantes para o classificador. Um método bastante conhecido é o *Sequential Backward Elimination* (SBE) (LADHA et al., 2011), o qual inicia o processo com todos os atributos, e aplica a classificação de um conjunto de amostras, eliminando um atributo por vez. Aquela eliminação que apresentar a melhor métrica (acurácia, por exemplo) é mantida. O processo segue com a eliminação de atributos até um critério de parada, como valor da métrica ou número de atributos mínimo.

5.2.3. Classificação

O objetivo desta etapa é receber as características extraídas dos dados, processá-las com um algoritmo classificador, e rotulá-las a uma das seis atividades que se desejam identificar. Neste trabalho, o classificador foi desenvolvido para operar, em tempo real, embarcado no dispositivo vestível. Por essa razão, durante a implementação do classificador, foi necessário considerar algumas restrições impostas pelas limitações de recursos do microcontrolador, como razoável velocidade de processamento, memória pequena, ausência de uma unidade de ponto flutuante em *hardware*, entre outras.

Torres-Huitzul e Alvarez-Landero (2015) mostraram que um classificador neural baseado em Perceptrons simples, construído de forma hierárquica, pode apresentar bons resultados na classificação de atividades humanas. Dada a simplicidade de implementação do Perceptron simples, optou-se, neste trabalho, por desenvolver o classificador com base em uma estrutura hierárquica de Perceptrons. Além desse, foi também desenvolvido um classificador baseado na rede neural MLP, e também outros

três classificadores implementados com ferramentas do Matlab, com o propósito de comparação. Foram comparados os seguintes classificadores:

- Perceptron de múltiplas camadas (MLP);
- Classificador hierárquico baseado em Perceptrons simples;
- Árvore de Decisão;
- k-NN;
- Naive Bayes.

Esta seção aborda as configurações dos classificadores desenvolvidos, a escolha de seus parâmetros, e as justificativas para se utilizar tais parâmetros. Os procedimentos dos testes realizados para avaliar os classificadores, bem como os resultados do desempenho destes, são apresentados no Capítulo 6.

5.2.3.1. Perceptron de múltiplas camadas (MLP)

Foi desenvolvida uma rede neural com arquitetura MLP e algoritmo de treinamento *backpropagation*, abordada com detalhes no Apêndice A. As principais vantagens dessa rede são o tempo de operação reduzido e a forte capacidade de generalização. Por outro lado, considerando a classificação embarcada no dispositivo vestível, a necessidade de realizar operações com ponto flutuante, como na normalização dos dados, no ajuste de pesos e na aplicação da função de ativação logística pode implicar erros de arredondamento e atraso no processamento, visto que o microcontrolador utilizado não possui unidade de ponto flutuante física.

A rede foi construída com as seguintes características:

- 10 entradas (vetor de características \mathbf{v} , definido pela Equação 12);
- uma camada oculta com cinco neurônios;
- três neurônios na camada de saída;
- função de ativação logística;
- taxa de aprendizagem η igual a 0,15;
- termo *momentum* α igual a 0,9;
- precisão igual a 10^{-4} .

Optou-se por apenas uma camada oculta para a rede não se tornar altamente complexa e, além disso, uma rede MLP com uma camada intermediária tem se mostrado eficiente nas propostas recentes de HAR com esse tipo de classificador (LUBINA; RUDZKI, 2015; VRIES et al., 2010).

Foram utilizados três neurônios na camada de saída para que fosse possível se obterem ao menos seis resultados diferentes combinando as saídas da rede de forma binária, como apresenta a Tabela 4, sendo N_0 , N_1 e N_2 os neurônios da camada de saída da rede.

Tabela 4 – Saídas da rede MLP e as atividades associadas.

N_2	N_1	N_0	Atividade
0	0	0	Sentado
0	0	1	Em pé
0	1	0	Andando
0	1	1	Subindo escadas
1	0	0	Descendo escadas
1	0	1	Correndo

O número de neurônios da camada oculta, a taxa de aprendizagem e a precisão do treinamento foram determinados com bases em testes preliminares apresentados na Seção 6.1.3. O procedimento dos testes realizados com o classificador MLP desenvolvido é descrito no Capítulo 6, bem como os resultados relativos ao desempenho do classificador.

5.2.3.2. Hierarquia de Perceptrons

Como descrito na Seção 3.2.5.6, e apresentado com detalhes no Apêndice A, um Perceptron é formado por apenas um neurônio e pode classificar um conjunto de

amostras em apenas duas classes, que sejam linearmente separáveis. Portanto, não é possível aplicar o Perceptron da maneira tradicional ao problema de classificação de padrões deste trabalho, pois o objetivo é classificar seis diferentes atividades.

No entanto, pode-se empregar o Perceptron para isolar uma classe de atividade das restantes, caso esses dois grupos sejam linearmente separáveis. Assim, pode-se aplicar o Perceptron, sequencialmente, separando uma atividade das outras, excluindo a atividade que já foi classificada, formando um classificador hierárquico. Com base nessa estrutura, desenvolveu-se um classificador para identificar as seis atividades do sistema de HAR proposto neste trabalho. A Figura 34 apresenta a configuração do classificador implementado, denominado Hierarquia de Perceptrons, com os quatro Perceptrons utilizados em sua construção: P_1 , P_2 , P_3 e P_4 . Considera-se que apenas as seis atividades escolhidas serão realizadas, ou seja, mesmo que uma atividade fora do contexto seja realizada, o algoritmo identificará como uma das seis pré-definidas.

Inicialmente, apresenta-se o vetor de características de uma determinada amostra que se deseja classificar, com os atributos normalizados. Uma regra de decisão, baseada no valor do desvio padrão normalizado da aceleração do eixo Y, define se a amostra é uma atividade estática ou dinâmica. Caso seja uma atividade estática, aplica-se o vetor de características v_1 ao Perceptron P_1 para se rotular a atividade como “em pé” ou “sentado”. Caso seja uma atividade dinâmica, inicia-se com a aplicação do vetor de atributos definido por v_2 ao Perceptron P_2 para se classificar entre “correndo” e “outras atividades”. Caso o resultado seja “outras atividades” prossegue-se com a aplicação do vetor de características v_3 ao Perceptron P_3 , obtendo como saída “subindo escadas” ou “outras atividades”. Caso a saída seja “outras atividades”, o Perceptron P_4 recebe o vetor de características v_4 , e o identifica como “descendo escadas” ou “andando”.

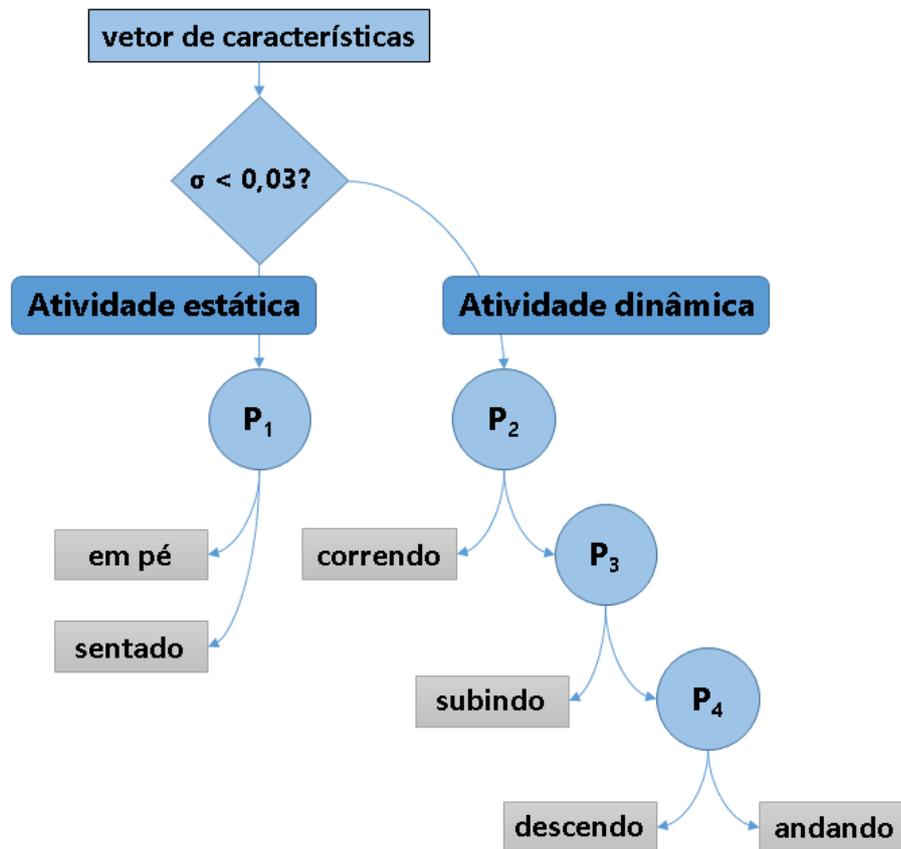


Figura 34 - Classificador hierárquico baseado em Perceptrons.

Para cada Perceptron, definiu-se um vetor de características com determinados atributos, de forma que esses atributos sejam linearmente separáveis para contribuir para um desempenho eficiente do classificador. A escolha dos atributos que compõem cada vetor de características baseou-se no método SBE, descrito na Seção 3.2.4, e os resultados são apresentados na Seção 6.1.4.1.

5.2.3.3. Outros classificadores

Com o propósito de comparar o desempenho dos classificadores neurais desenvolvidos para o sistema de HAR proposto, utilizaram-se outros três classificadores, implementados com funções já implementadas do Matlab, sendo eles: Árvore de Decisão, k-NN e Naive Bayes. A Seção 3.2.5 descreve brevemente o funcionamento desses algoritmos. Na sequência são apresentadas algumas considerações sobre os classificadores.

- **Árvore de Decisão:** adotou-se o algoritmo CART (BREIMAN et al., 1984), o qual utiliza o índice de diversidade de Gini como métrica para escolha do atributo a ser testado em cada nó.
- **k-NN:** utilizou-se a distância euclidiana como métrica de distância entre amostras, e k igual 5 vizinhos.
- **Naive Bayes:** considerou-se que os atributos têm valores distribuídos normalmente.

5.3. MONITORAMENTO DE ATIVIDADE

Para as abordagens relativas ao monitoramento da intensidade das atividades realizadas pelo usuário, foram desenvolvidas técnicas para medir e armazenar parâmetros extraídos da aceleração quando o usuário está utilizando o dispositivo vestível. Esta seção apresenta o funcionamento das técnicas empregadas para as abordagens A_2 e A_3 do sistema desenvolvido.

5.3.1. Desvio padrão da aceleração

Buscando medir o nível da intensidade das atividades praticadas pelo usuário, implementou-se um algoritmo para calcular e armazenar o desvio padrão da aceleração do dispositivo vestível utilizado pelo usuário ao longo do dia. Nesta abordagem (A_2), o dispositivo vestível é utilizado como uma pulseira, como mostra a Figura 21b da Seção 4.2.6, e a variável de interesse é o módulo da aceleração nos três eixos (Equação 13). A aceleração \bar{a}_e em cada eixo e é calculada como mostra a Equação 12, sendo n cada leitura do acelerômetro a 100 Hz, e i uma leitura média a 10 Hz.

$$\bar{a}_{e,i} = \frac{1}{10} \sum_{n=1}^{10} a_{e,n} \quad (12)$$

$$\bar{a}_i = \sqrt{(\bar{a}_{x,i}^2 + \bar{a}_{y,i}^2 + \bar{a}_{z,i}^2)} \quad (13)$$

Como descrito na Seção 4.3.2, o *firmware* desenvolvido para esta abordagem calcula o desvio padrão de uma janela de dados de um segundo, e armazena a média desse parâmetro a cada minuto. O desvio padrão da janela de um segundo (10 amostras) é calculado como mostra a Equação 14, enquanto a Equação 15 define o cálculo do desvio padrão médio a cada minuto.

$$\sigma = \frac{1}{10} \sum_{i=1}^{10} a_i \quad (14)$$

$$\bar{\sigma}_{1min} = \frac{1}{60} \sum_{j=1}^{60} \sigma_j \quad (15)$$

A Seção 6.2.1 mostra os resultados do monitoramento remoto utilizando esta abordagem. Também é apresentada uma comparação do desvio padrão calculado quando uma pessoa realiza diferentes atividades do cotidiano.

5.3.2. Contador de passos

Um algoritmo contador de passos foi desenvolvido para a abordagem A_3 . Neste caso, o usuário utiliza o dispositivo vestível como um cinto, na cintura, e adota-se apenas a aceleração do eixo Y, que está orientado na direção do eixo longitudinal do corpo humano, como mostra a Figura 31 da Seção 5.2. Nesta abordagem, o *firmware* desenvolvido, descrito na Seção 4.3.3, executa a função contador de passos a uma taxa de 10 Hz, recebendo um novo valor médio de aceleração, \bar{a}_y , calculado a partir da média de 10 amostras da aquisição a 100 Hz do acelerômetro.

Portanto, o algoritmo “contador de passos”, mostrado na Figura 35, é executado a cada 100 ms, quando o sistema está em operação, e funciona como descrito a seguir. Assim que se executa a função, o algoritmo atualiza os valores máximos e mínimos do ciclo de aceleração, ou seja, o valor máximo mantém o maior valor desde o último vale, e o valor mínimo mantém o menor valor desde o último pico. A seguir, calcula-se a derivada do sinal, sendo definida pela diferença entre o valor de aceleração atual

e o valor obtido no ciclo anterior, como mostra a Equação 16, sendo \bar{a}_y definido pela Equação 4.

$$d[n] = \bar{a}_y[n] - \bar{a}_y[n - 1] \quad (16)$$

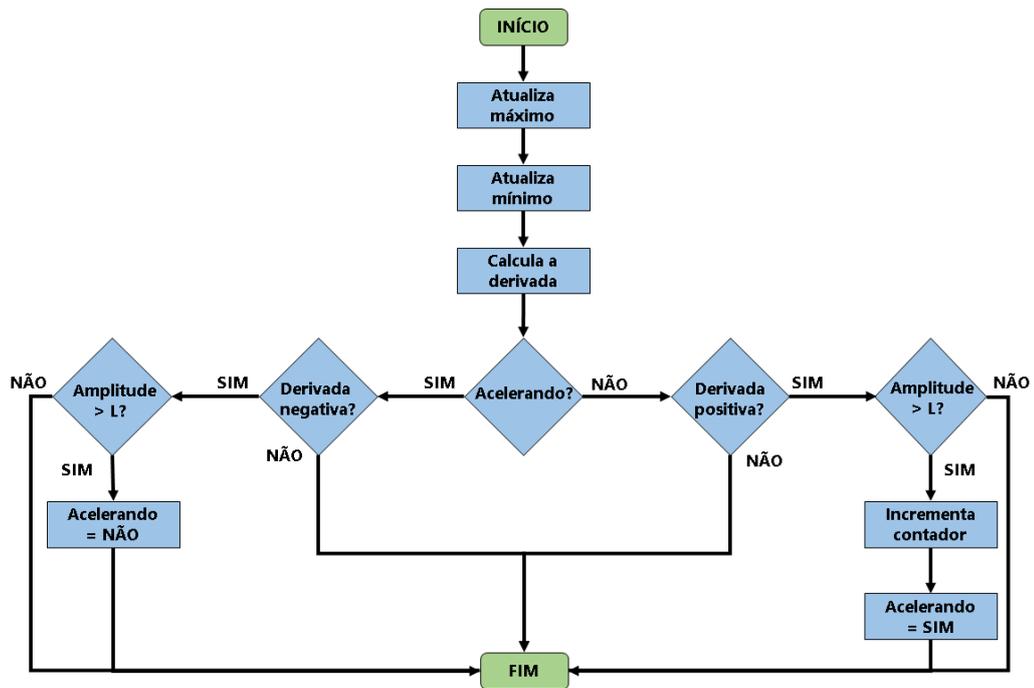


Figura 35 - Fluxograma do contador de passos.

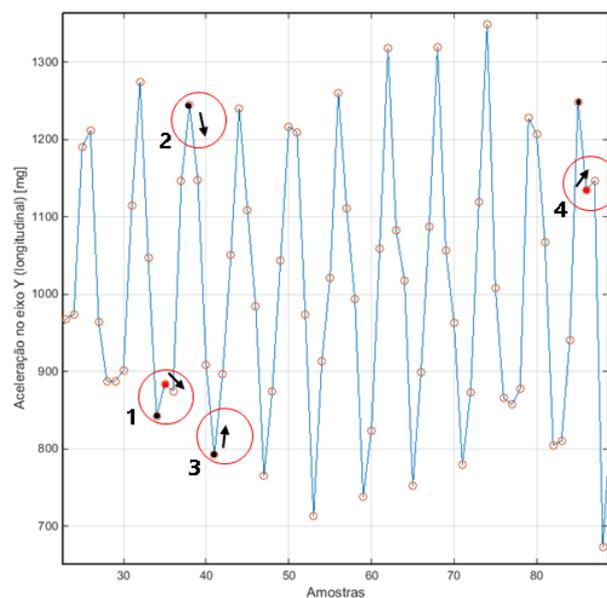


Figura 36 - Aceleração no eixo Y durante caminhada e destaques.

A Figura 36 mostra um exemplo de dados coletados da aceleração no eixo Y durante uma caminhada, com pontos importantes destacados. Enquanto o dispositivo estiver em aceleração, ou seja, com derivada positiva, busca-se uma derivada negativa, a cada vez que se executa o algoritmo. Quando se obtém uma derivada negativa, um pico do sinal é identificado. Caso a diferença entre esse pico e o último vale seja superior a um determinado limiar L , considera-se o pico um falso positivo (destaque 1 da Figura 36), descarta-se o pico, e o processo continua. Caso a diferença seja maior que L , o dispositivo iniciou o processo de desaceleração (destaque 2 da Figura 36). Busca-se então, a cada execução do algoritmo, uma derivada positiva, para identificação de um vale. Quando se encontra (destaque 3 da Figura 36), calcula-se a diferença entre o último pico e o vale encontrado, e aplica-se a mesma regra do caso anterior. Se não for um falso positivo, completou-se um passo, e o contador é incrementado. Um exemplo de falso positivo para um vale é mostrado no destaque 4 da Figura 36, onde a diferença deste para o último pico é menor que L . O valor do limiar L , no estágio atual do trabalho, deve ser estabelecido com base em observações prévias dos dados de aceleração coletados do usuário que vai utilizar o sistema. Futuramente, pretende-se desenvolver um algoritmo adaptativo para realizar esta função.

6. TESTES E RESULTADOS

Este capítulo aborda os procedimentos adotados na realização dos testes com o dispositivo vestível para avaliação das três abordagens desenvolvidas neste trabalho, e, posteriormente, são apresentados e discutidos os resultados obtidos. Os testes realizados têm o objetivo de validar o sistema proposto, considerando as três abordagens, para oferecê-lo como solução aos projetos em desenvolvimento no NTA no contexto deste trabalho, como monitoramento de pessoas com Transtorno Afetivo Bipolar (TAB) e de pessoas com doenças crônicas.

6.1. RECONHECIMENTO DE ATIVIDADES HUMANAS (HAR)

Esta seção apresenta os testes e os resultados do processo de implementação dos classificadores neurais desenvolvidos, bem como os resultados do desempenho desses classificadores no sistema de HAR. Os resultados são comparados com aqueles obtidos com outros três classificadores e por sistemas propostos recentemente na literatura. Finalmente, apresentam-se os resultados do classificador embarcado no dispositivo vestível.

6.1.1. Coleta de dados para implementação dos classificadores

Foram coletados dados para treinamento e avaliação do desempenho dos classificadores implementados para a abordagem A_1 do sistema desenvolvido. Os dados foram coletados de cinco indivíduos saudáveis, sendo três do sexo masculino e dois do sexo feminino, com idade média de $28,80 \pm 3,42$ anos.

Desenvolveu-se um aplicativo móvel específico para a coleta dos dados, o qual recebe os dados de aceleração do dispositivo vestível, e os armazena no *smartphone*, para formar a base de dados de treinamento e teste dos classificadores. Cada pessoa participante dos testes foi orientada a realizar o seguinte procedimento, com o auxílio de um operador responsável pela coleta, que opera o aplicativo no *smartphone*:

- Vestir o dispositivo, como um cinto, na cintura;

- Posicionar-se em pé com postura ereta, e executar a calibração do dispositivo pelo aplicativo móvel.
- Realizar as seguintes atividades por um período entre 30 segundos e um minuto, com o dispositivo coletando dados e os enviando para o *smartphone*:
 - Caminhar;
 - Subir escadas;
 - Descer escadas;
 - Correr em uma esteira;
 - Permanecer em pé parado;
 - Permanecer sentado.

Os dados das atividades “subindo escadas” e “descendo escadas” foram coletados de maneira descontínua para acumular o período desejado, pois não havia disponível uma sequência de degraus suficiente para coleta contínua dos dados por esse período de tempo.

Os dados foram coletados de acordo com a configuração de aquisição e segmentação do processo de HAR (abordagem A₁). Após a coleta, os dados foram transferidos para um computador, onde se realizou o tratamento dos dados para treinamento e testes dos classificadores. Os dados de aceleração nos eixos Y e Z coletados foram segmentados em janelas de dois segundos (20 amostras), com sobreposição de um segundo, totalizando 1432 amostras, distribuídas por atividade como mostra a Tabela 5.

A Figura 37 mostra um exemplo de dados de aceleração dos eixos Y e Z, respectivamente, longitudinal e sagital do corpo humano, quando o usuário se encontra em repouso. Na Figura 37a, observam-se dados da atividade “sentado”, e na Figura 37b, dados da atividade “em pé”. Nota-se que, nestas atividades, basicamente se mede a influência da aceleração gravitacional sobre o dispositivo, que varia de acordo com a postura do usuário.

Tabela 5 - Distribuição de amostras coletadas.

Atividade	Nº de amostras
Sentado	161
Em pé	173
Andando	287
Subindo escadas	325
Descendo escadas	285
Correndo	209

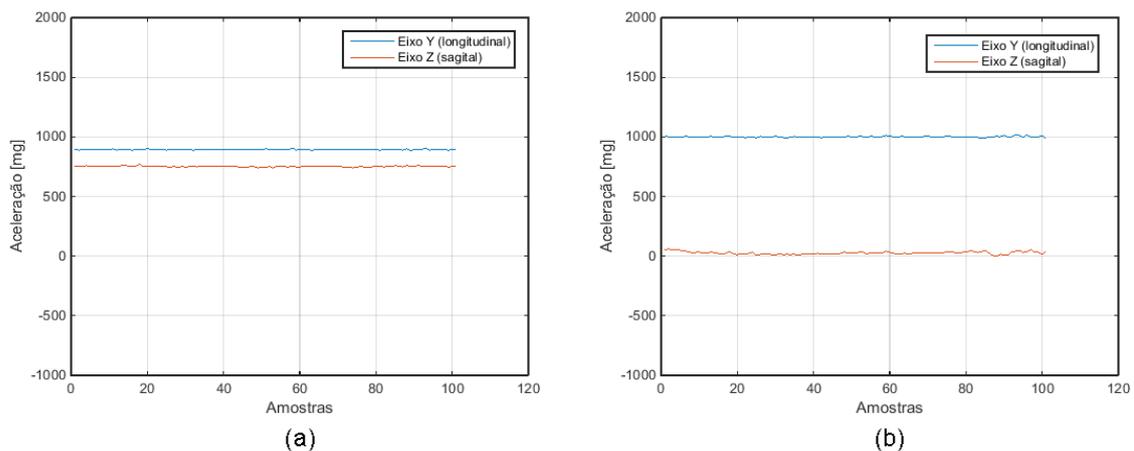


Figura 37 - Aceleração nos eixos Y e Z das atividades: a) sentado; b) em pé.

A Figura 38a mostra um exemplo da aceleração medida nos eixos Y e Z do acelerômetro quando se executa a atividade “andando”, enquanto a Figura 38b apresenta um exemplo da atividade “correndo”. Observa-se um sinal de maior amplitude da aceleração no eixo Y da atividade “correndo” em relação à atividade “andando”, o que implica maior desvio padrão, maior faixa do sinal, e maior SMA, atributos estes extraídos dos dados no processo de reconhecimento de atividades.

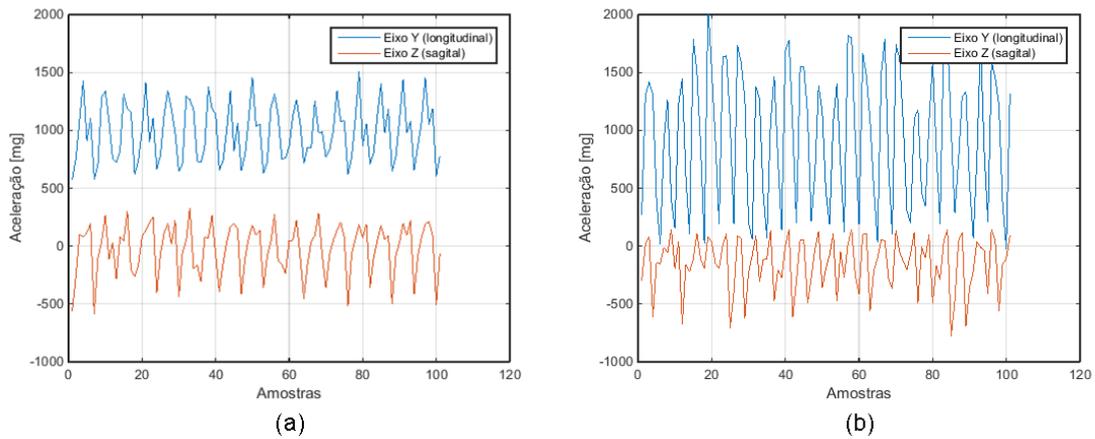


Figura 38 - Aceleração nos eixos Y e Z das atividades: a) andando; b) correndo.

As Figuras 39a e 39b mostram, respectivamente, exemplos de dados de aceleração das atividades “subindo escadas” e “descendo escadas”. Pode-se observar que, para o usuário do qual os dados foram coletados, houve maior aceleração no eixo longitudinal ao descer escadas, e a aceleração no eixo sagital apresentou padrões distintos entre as atividades, apesar de terem amplitude semelhante.

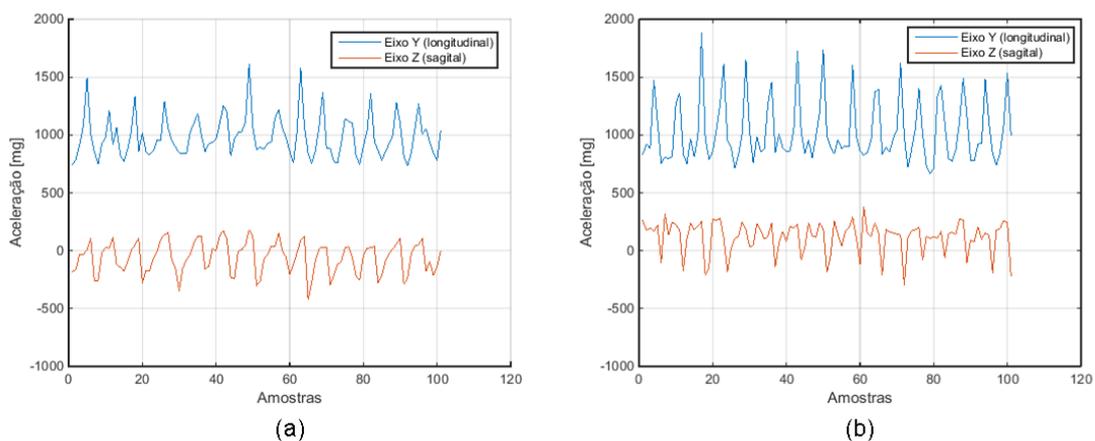


Figura 39 - Aceleração nos eixos Y e Z das atividades: a) subindo escadas; b) descendo escadas.

Previamente ao processo de treinamento dos classificadores, aplica-se a extração de características, descrita na Seção 5.2.2, sobre os dados coletados, e se normalizam os valores resultantes em um intervalo entre zero e um.

Para exemplificar graficamente os valores obtidos pela extração de características, bem como a facilidade ou dificuldade em identificar diferentes atividades com determinados atributos, apresentam-se as seguintes figuras. A Figura 40 mostra uma

comparação entre as atividades estáticas e dinâmicas, baseada no desvio padrão da aceleração dos eixos longitudinal e sagital do corpo humano. Como esperado, quando o usuário se encontra em repouso, o sinal permanece próximo à média, com pouca variação, como mostrado na Figura 37, portanto com desvio padrão reduzido. Neste caso seria possível separar as atividades com a aplicação de uma simples regra baseada em limiar.

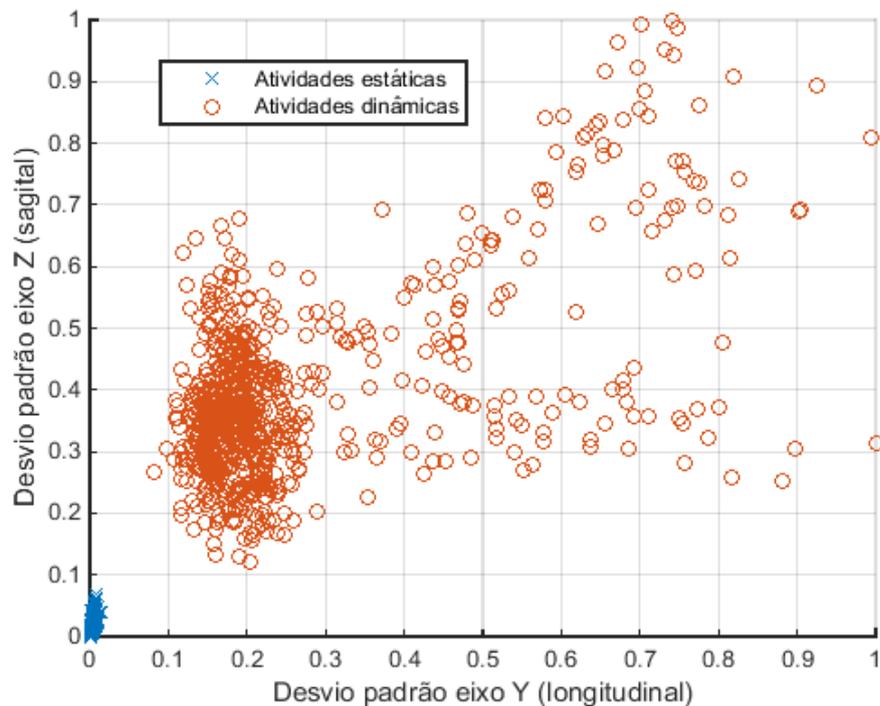


Figura 40 – Comparação gráfica entre as atividades estáticas e dinâmicas.

A Figura 41 mostra o gráfico do valor da média da aceleração do eixo longitudinal pela média da aceleração do eixo sagital, para as duas atividades estáticas: “sentado” e “em pé”. A média da aceleração em um eixo do acelerômetro filtra as variações do sinal e carrega a informação de um valor médio relacionado à aceleração gravitacional projetada naquele eixo. Portanto, a média se relaciona com a postura adotada pelo usuário, e, logo, mostra-se um excelente atributo para diferenciar as atividades estáticas com o dispositivo localizado na cintura do usuário.

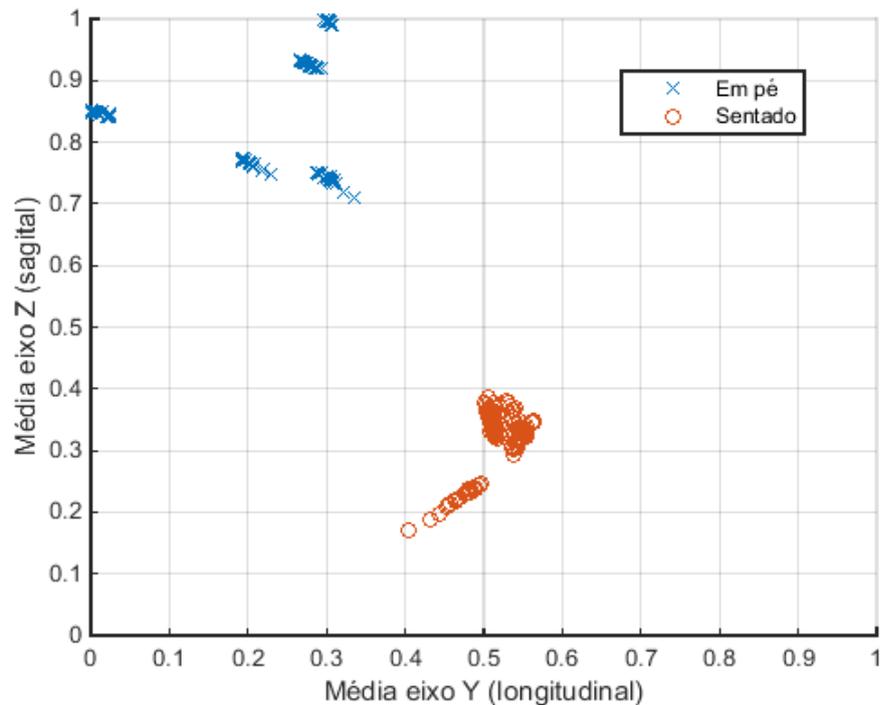


Figura 41 – Comparação gráfica entre as atividades “sentado” e “em pé”.

A Figura 42 mostra uma comparação entre as atividades “correndo” e as outras dinâmicas. O gráfico representa os dados do desvio padrão dos eixos longitudinal e sagital. Como um indivíduo gera maior aceleração e, conseqüentemente, desaceleração, ao correr, essa atividade apresenta maior desvio padrão, como se observa no gráfico (Figura 42). Nota-se que ainda há uma interseção razoável de dados, a qual pode ser evitada quando se usam mais atributos.

Por outro lado, as atividades “andando”, “subindo escadas” e “descendo escadas” apresentaram características estatísticas extraídas do sinal bastante semelhantes. A Figura 43 mostra o gráfico da média da aceleração no eixo longitudinal pela média da aceleração no eixo sagital, em relação a essas atividades. Já o gráfico da Figura 44 apresenta a comparação dessas três atividades em relação ao desvio padrão da aceleração nos eixos longitudinal e sagital. E a Figura 45 exhibe o gráfico da mediana da aceleração no eixo sagital pela SMA do sinal no eixo longitudinal, também dessas três atividades. Pode-se notar nessas três figuras que, apesar de existir um certo agrupamento por atividade, há uma interseção considerável, prejudicando a separação das atividades.

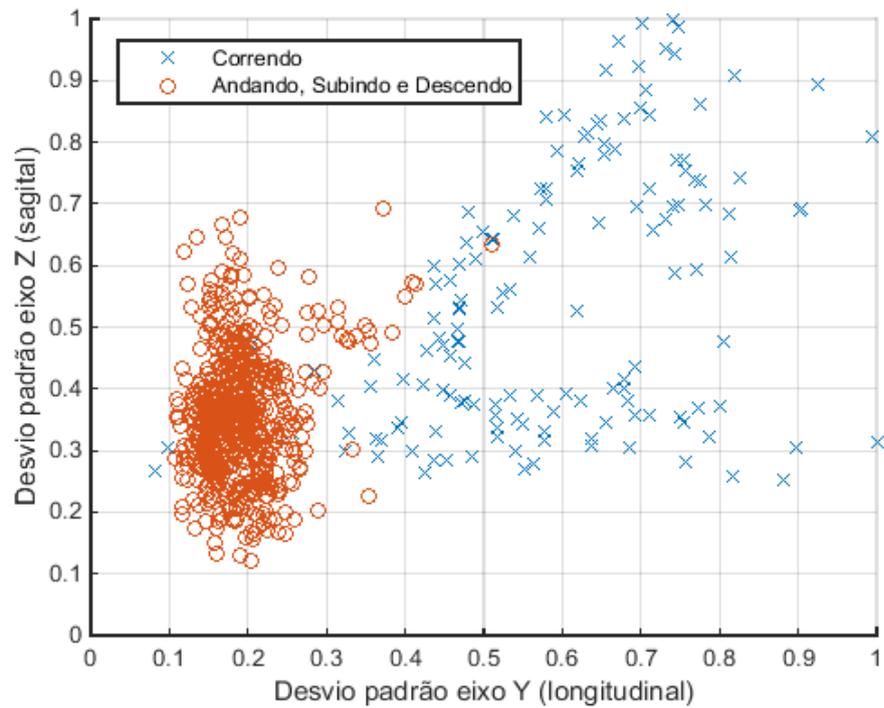


Figura 42 - Comparação gráfica entre a atividade "correndo" e as outras atividades dinâmicas.

A Figura 46 mostra o gráfico da mediana da aceleração no eixo longitudinal pela faixa do sinal da aceleração no eixo sagital das atividades “andando”, “subindo escadas” e “descendo escadas”. Com a combinação desses dois atributos, praticamente não se observa agrupamento por atividade, e a interseção ocorre em todo o espaço onde se encontram dados. Esse é um caso de combinação de atributos que pode apenas prejudicar o processo de classificação, fazendo-se necessária uma seleção de atributos eficiente para evitar essa situação.

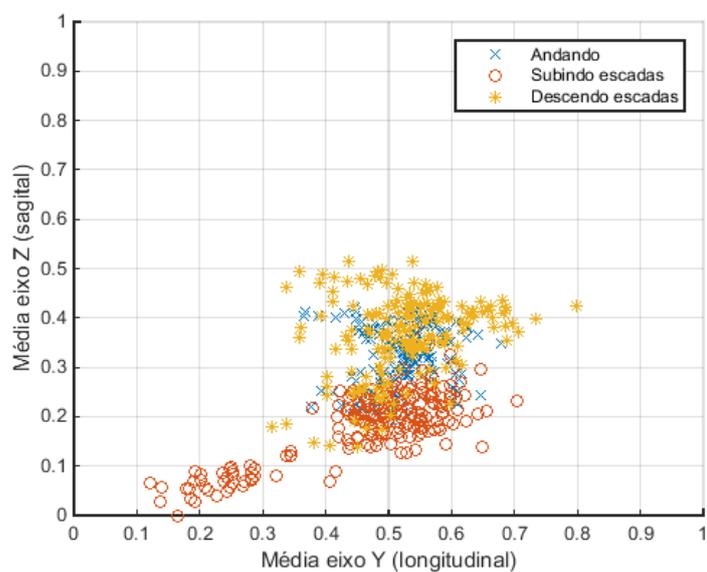


Figura 43 - Comparação gráfica entre as atividades "andando", "subindo escadas" e "descendo escadas", em relação às médias da aceleração nos eixos Y e Z.

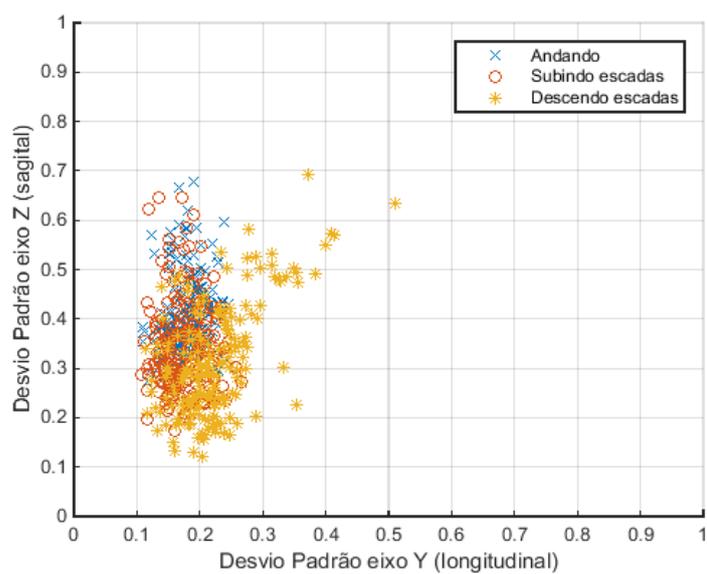


Figura 44 - Comparação gráfica entre as atividades dinâmicas "andando", "subindo escadas" e "descendo escadas", em relação ao desvio padrão da aceleração nos eixos Y e Z.

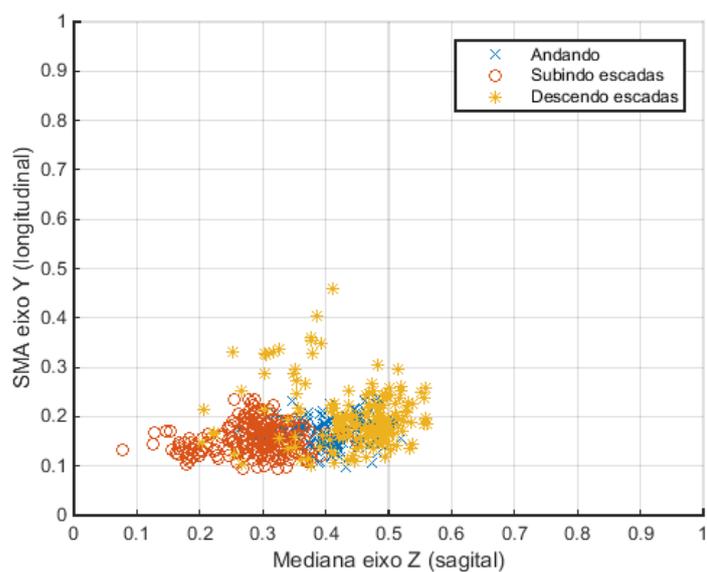


Figura 45 - Comparação gráfica entre as atividades "andando", "subindo escadas" e "descendo escadas", em relação à mediana da aceleração no eixo Z e da SMA da aceleração no eixo Y.

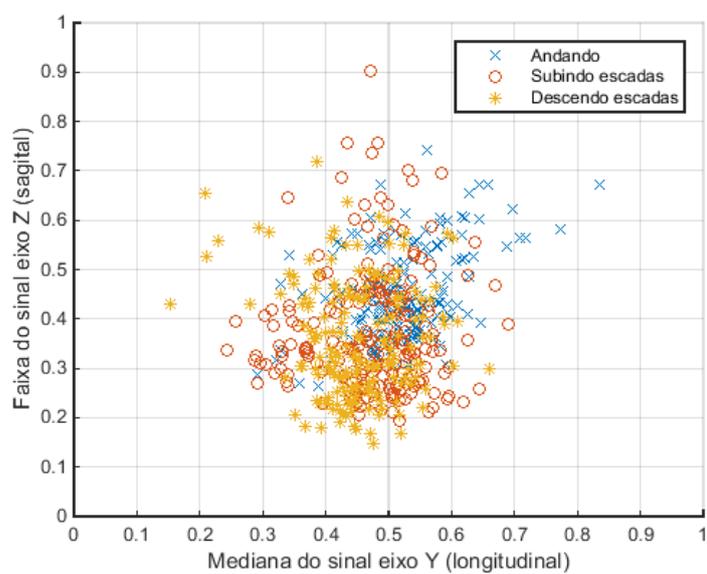


Figura 46 - Comparação gráfica entre as atividades "andando", "subindo escadas" e "descendo escadas", em relação à mediana da aceleração no eixo Y e da faixa do sinal da aceleração no eixo Z.

6.1.2. Validação cruzada

No processo de treinamento e teste dos classificadores desenvolvidos, utilizou-se um método de validação cruzada denominada *k*-partições, bastante conhecido no termo em inglês *k-fold cross-validation* (SILVA; SPATTI; FLAUZINO, 2010). Neste método, divide-se o conjunto total de amostras em *k* partições, sendo que *k-1* são utilizadas para compor o subconjunto de treinamento, enquanto a partição restante constitui o subconjunto de teste.

Neste trabalho adotaram-se quatro partições, sendo três utilizadas para treinamento, e uma para teste, de forma alternada, em quatro rodadas (R₁, R₂, R₃ e R₄), como mostra a Tabela 6, até que todas as partições tenham sido utilizadas como subconjunto de teste. Os dados gerados pelo processo de extração de características e normalizados são divididos nas quatro partições que vão compor os subconjuntos de treinamento e de teste. Cada partição é composta por 358 amostras de 10 atributos, representadas pelo vetor de características da Equação 12 normalizado.

Tabela 6 - Divisão das partições por rodadas de teste.

Rodada	Subconjunto de treinamento	Subconjunto de teste
R1	Partições 2, 3 e 4	Partição 1
R2	Partições 1, 3 e 4	Partição 2
R3	Partições 1, 2 e 4	Partição 3
R4	Partições 1, 2 e 3	Partição 4

6.1.3. Perceptron de múltiplas camadas (MLP)

Esta seção apresenta os testes realizados para definição de parâmetros da rede MLP e o desempenho alcançado pela rede ao classificar as seis atividades.

6.1.3.1. Definição do número de neurônios na camada oculta

Para definição dos parâmetros, foram realizados testes preliminares com um dos subconjuntos de treinamento da Tabela 6, composto por três partições, do qual se utilizaram 75% para treinamento e 25% para teste. Foram realizados cinco testes (T_1 , T_2 , T_3 , T_4 e T_5), e avaliou-se a média da acurácia obtida.

Para definir o número de neurônios adequado para a camada oculta da rede MLP desenvolvida, variou-se a quantidade de neurônios entre 5, 10, 15 e 20, executando o treinamento e o teste cinco vezes, e se avaliou a acurácia média obtida pela rede. Foram definidas taxa de aprendizagem igual a 0,15 e precisão igual a 10^{-4} . Obteve-se a melhor acurácia para a topologia com 5 neurônios na camada oculta, como mostra a Tabela 7.

Tabela 7 - Acurácia da rede MLP para diferentes topologias da rede.

Nº de neurônios	Acurácia					
	T_1	T_2	T_3	T_4	T_5	Média
5	86,59%	87,15%	87,71%	87,71%	87,99%	87,43%
10	87,71%	87,99%	86,87%	86,87%	87,15%	87,32%
15	87,15%	87,43%	86,59%	86,03%	87,15%	86,87%
20	86,31%	86,03%	86,87%	86,87%	86,59%	86,53%

6.1.3.2. Definição da taxa de aprendizagem

Para escolha da taxa de aprendizagem adequada para treinamento da rede, variou-se a taxa entre os valores entre 0,10, 0,15, 0,20, 0,25 e 0,50, ao se executar cinco treinamentos e testes. Foram utilizados 5 neurônios na camada oculta e precisão igual a 10^{-4} . Os resultados, apresentados na Tabela 8, mostraram que ao se usar a taxa de aprendizagem igual a 0,15, a rede obteve o melhor desempenho.

Tabela 8 - Acurácia da rede MLP por taxa de aprendizagem.

Taxa de aprendizagem	Acurácia					
	T ₁	T ₂	T ₃	T ₄	T ₅	Média
0,10	86,87%	83,52%	86,87%	87,99%	86,59%	86,37%
0,15	86,59%	87,15%	87,71%	87,71%	87,99%	87,43%
0,20	87,43%	85,2%	86,59%	86,59%	86,87%	86,54%
0,25	86,31%	85,75%	87,15%	86,87%	86,31%	86,48%
0,50	85,47%	86,31%	86,59%	85,47%	84,92%	85,75%

6.1.3.3. Definição da precisão

Neste caso, avaliou-se o desempenho do classificador para precisões de 10^{-3} , 10^{-4} e 10^{-5} como critério de parada no processo de treinamento. A Tabela 9 mostra que uma precisão igual a 10^{-4} resultou na melhor acurácia.

Tabela 9 - Acurácia da rede MLP por precisão.

Precisão	Acurácia					
	T ₁	T ₂	T ₃	T ₄	T ₅	Média
10^{-4}	83,24%	81,28%	81,56%	82,4%	81,28%	81,95%
10^{-5}	86,59%	87,15%	87,71%	87,71%	87,99%	87,43%
10^{-6}	83,80%	84,92%	85,47%	83,80%	84,64%	84,53%

6.1.3.4. Desempenho da rede MLP

Com os parâmetros definidos, a rede MLP implementada foi configurada como apresenta a Seção 5.2.3.1. Para avaliação do desempenho, adotou-se a técnica de validação cruzada com 4 partições, separadas e combinadas em subconjuntos de

treinamento e de teste, como mostra a Tabela 6. Foram realizados o treinamento e o teste nas quatro rodadas, e calculou-se a média da acurácia, da precisão e da revocação obtidas, apresentadas na Tabela 10.

Tabela 10 - Desempenho da rede MLP.

Classificador	Acurácia					Precisão	Revocação
	R ₁	R ₂	R ₃	R ₄	Média		
MLP	88,27%	84,92%	80,17%	88,55%	85,47±3,90%	88,86%	88,15%

A matriz de confusão desse classificador é mostrada na Tabela 11, na qual se observa que as atividades estáticas foram corretamente classificadas, enquanto a maior dificuldade ocorreu para classificar as atividades “andando” e “descendo escadas”.

Tabela 11 - Matriz de confusão da rede MLP.

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
Atividades classificadas	Sentado	100,00%	0,00%	0,35%	0,31%	3,24%	0,00%
	Em pé	0,00%	100,00%	0,00%	0,31%	0,36%	0,00%
	Andando	0,00%	0,00%	66,31%	1,86%	12,23%	0,00%
	Subindo	0,00%	0,00%	26,24%	96,89%	7,19%	2,88%
	Descendo	0,00%	0,00%	7,09%	0,00%	69,42%	0,96%
	Correndo	0,00%	0,00%	0,00%	0,62%	7,55%	96,15%

Buscando melhorar o desempenho do classificador, aplicou-se o método de seleção de atributos SBE, visto que alguns atributos podem apenas prejudicar o classificador, como se abordou na Seção 3.2.4. Na aplicação do algoritmo, adotou-se a métrica acurácia para avaliação dos melhores atributos para o classificador. Utilizou-se um

dos subconjuntos de treinamento, do qual se separou 75% para treinamento e 25% para testes.

Inicialmente apresentaram-se os 10 atributos e se realizaram o treinamento e o teste cinco vezes, calculando, ao final, a média da acurácia. No passo seguinte realizou-se o mesmo procedimento, porém, eliminando um dos atributos por vez, e se observou qual retirada contribuiu para a melhor acurácia. O respectivo atributo foi então eliminado do processo. Nos passos seguintes, o processo foi repetido, até que sobrasse apenas um atributo. Finalmente, foi escolhido o conjunto de atributos que representou a melhor acurácia para formar o novo vetor de características, no caso, definido por:

$$v_{MLP} = [\mu_y, \mu_z, \sigma_y, \sigma_z, m_y, r_y, sma_z] \quad (17)$$

Utilizando o vetor de características definido pela Equação 17, repetiu-se o processo de avaliação do desempenho da MLP, utilizando a técnica de validação cruzada. A Tabela 12 apresenta a acurácia obtida a cada rodada, e sua média, bem como a precisão e revocação do classificador. Com a seleção de atributos, o classificador melhorou a identificação da atividade “andando”, porém, piorou nas outras três atividades dinâmicas, como mostra a matriz de confusão da Tabela 13.

Tabela 12 - Desempenho da rede MLP com seleção de atributos.

Classificador	Acurácia					Precisão	Revocação
	R1	R2	R3	R4	Média		
MLP	87,15%	86,87%	80,17%	87,99%	85,54±3,62%	88,49%	88,26%

Tabela 13 - Matriz de confusão da rede MLP com seleção de atributos.

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
Atividades classificadas	Sentado	100,00%	0,00%	0,00%	0,00%	5,43%	0,00%
	Em pé	0,00%	99,42%	0,00%	0,31%	0,72%	0,00%
	Andando	0,00%	0,00%	71,33%	3,09%	14,49%	0,00%
	Subindo	0,00%	0,58%	22,22%	95,37%	5,80%	3,85%
	Descendo	0,00%	0,00%	6,45%	0,31%	67,75%	0,48%
	Correndo	0,00%	0,00%	0,00%	0,93%	5,80%	95,67%

6.1.4. Hierarquia de Perceptrons

Esta seção aborda as etapas de construção do classificador neural baseado em Perceptrons, ou seja, a escolha dos atributos que melhor separam as classes em cada Perceptron que compõe o classificador. Posteriormente são apresentados os resultados do desempenho desse classificador.

6.1.4.1. Definição dos atributos por Perceptron

No processo de implementação do classificador neural hierárquico baseado em Perceptrons simples, apresentado na Seção 5.2.3.2, foi empregada a técnica de seleção de atributos SBE para selecionar os melhores atributos para cada Perceptron. Dessa forma, podem-se encontrar aqueles atributos que fazem com que as amostras de classes diferentes sejam linearmente separáveis, ou, ao menos, a grande maioria das amostras de classes distintas.

A estrutura neural hierárquica implementada é mostrada na Figura 34 da Seção 5.2.3.2. Para o Perceptron P_1 , que classifica as amostras entre as classes “em pé” ou

“sentado”, os atributos foram selecionados por observação dos dados. Como mostra a Figura 41, quando se utiliza a média da aceleração nos eixos Y e Z para representar essas atividades, as amostras podem ser facilmente separadas por uma reta. Portanto, define-se o vetor de características do Perceptron P₁ como:

$$v_{P1} = [\mu_y, \mu_z] \quad (18)$$

Na sequência, foi empregado o método SBE para seleção dos atributos a serem aplicados aos Perceptrons P₂, P₃ e P₄, da mesma forma como se aplicou para o MLP. Para o Perceptron P₂, a melhor acurácia ocorreu quando se eliminou o atributo desvio padrão da aceleração no eixo Z. As rodadas de eliminações subsequentes não apresentaram incremento da acurácia, portanto, definiu-se o vetor de características como:

$$v_{P2} = [\mu_y, \mu_z, \sigma_y, m_y, m_z, r_y, r_z, sma_y, sma_z] \quad (19)$$

Para o Perceptron P₃, que separa a atividade “subindo escadas” das demais, aplicou-se a técnica SBE, e se obteve o vetor de características definido pela Equação 20. Enquanto para o Perceptron P₄, o método SBE determinou que o vetor de características definido pela Equação 21 tem o melhor desempenho.

$$v_{P3} = [\mu_y, \sigma_z, m_y, m_z, r_y, r_z, sma_y, sma_z] \quad (20)$$

$$v_{P4} = [\sigma_y, m_y, sma_y, sma_z] \quad (21)$$

6.1.4.2. Desempenho da Hierarquia de Perceptrons

Com os vetores de características definidos para cada Perceptron que forma o classificador, empregou-se a técnica de validação cruzada com as 4 partições, e foram realizados o treinamento e o teste em quatro rodadas. A Tabela 14 apresenta os resultados do desempenho deste classificador. A matriz de confusão, exibida na Tabela 15, mostra que houve uma melhoria considerável na taxa de acertos da

atividade “andando”, e uma pequena queda na acurácia de outras atividades dinâmicas, em relação à rede MLP.

Tabela 14 - Desempenho da Hierarquia de Perceptrons.

Classificador	Acurácia					Precisão	Revocação
	R1	R2	R3	R4	Média		
Hierarquia de Perceptrons	88,55%	86,31%	90,50%	91,06%	89,11±2,15%	91,45%	90,76%

Tabela 15 - Matriz de confusão da Hierarquia de Perceptrons.

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
		Atividades classificadas	Sentado	100,00%	0,00%	0,00%	0,00%
Em pé	0,00%	98,84%	0,00%	0,00%	0,00%	0,00%	0,00%
Andando	0,00%	0,00%	83,10%	7,41%	17,25%	0,00%	
Subindo	0,00%	1,16%	9,86%	91,36%	5,99%	3,37%	
Descendo	0,00%	0,00%	7,04%	0,93%	76,06%	1,44%	
Correndo	0,00%	0,00%	0,00%	0,31%	0,70%	95,19%	

6.1.5. Outros classificadores

Esta seção apresenta os resultados obtidos com os classificadores implementados com ferramentas do Matlab, que foram: Árvore de Decisão, k-NN e Naive Bayes, para comparação com aqueles desenvolvidos neste trabalho. Igualmente aos casos anteriores, empregou-se o método da validação cruzada com 4 partições para avaliação dos resultados. A Tabela 16 mostra os resultados de cada rodada, e a média da acurácia, da precisão e da revocação.

Tabela 16 - Desempenho dos classificadores.

Classificador	Acurácia					Precisão	Revocação
	R ₁	R ₂	R ₃	R ₄	Média		
Árvore de Decisão	86,31%	85,75%	78,21%	77,93%	82,05±4,60%	84,31%	81,54%
k-NN	89,39%	91,62%	83,80%	89,66%	88,62±3,36%	91,32%	90,26%
Naive Bayes	82,68%	87,43%	82,96%	82,68%	83,94±2,33%	86,57%	86,39%

Observa-se que, entre esses três classificadores, o k-NN apresentou o melhor desempenho, tanto em termos de acurácia, como de precisão e revocação. Para avaliação da influência prejudicial de alguns atributos, executou-se a técnica de seleção de atributos SBE, seguindo o mesmo processo realizado para a rede MLP, e obtiveram-se os seguintes vetores de características, respectivamente, para a Árvore de Decisão, para o k-NN e para o Naive Bayes.

$$\mathbf{v}_{\text{Árvore}} = [m_z, r_z, sma_y, sma_z] \quad (22)$$

$$\mathbf{v}_{\text{k-NN}} = [\mu_y, \mu_z, \sigma_y, \sigma_z, r_y, r_z, sma_z] \quad (23)$$

$$\mathbf{v}_{\text{Naive Bayes}} = [m_z, r_y, sma_z] \quad (24)$$

Nota-se que o atributo área do módulo do sinal (SMA) da aceleração no eixo Z aparece em todos os três vetores de características para esses classificadores, indicando que se trata de um atributo com informações relevantes para o processo de HAR. Por outro lado, a mediana da aceleração no eixo Y não foi selecionada em nenhum dos casos, o que indica que esse atributo tem informações irrelevantes para o processo, e prejudica o desempenho dos classificadores.

Novamente, aplicou-se o método de validação cruzada com as quatro partições, e os resultados se apresentam na Tabela 17. Nota-se que a seleção de atributos foi fundamental para uma melhoria do desempenho da Árvore de Decisão, principalmente na métrica revocação, que indica que a árvore reduziu bastante sua

taxa de falsos negativos. O k-NN não demonstrou melhoria em nenhuma métrica de avaliação, sendo, portanto, indicado trabalhar com todos os atributos com esse classificador. No caso do Naive Bayes, houve uma ligeira queda de acurácia com os atributos selecionados, enquanto a precisão aumentou, também ligeiramente, indicando que a taxa de falsos positivos decrementou.

Tabela 17 - Desempenho dos classificadores com seleção de atributos.

Classificador	Acurácia					Precisão	Revocação
	R1	R2	R3	R4	Média		
Árvore de Decisão	87,15%	84,64%	82,40%	84,64%	84,71±1,94%	87,22%	87,05%
k-NN	92,74%	89,94%	85,20%	86,31%	88,55±3,45%	90,52%	90,22%
Naive Bayes	86,87%	84,08%	79,61%	84,92%	83,87±3,07%	87,11%	86,13%

6.1.6. Comparação do desempenho dos classificadores

Ente os dois classificadores neurais desenvolvidos neste trabalho e os outros três implementados com ferramentas do Matlab, a Hierarquia de Perceptrons mostrou o melhor desempenho, em relação às três métricas utilizadas (acurácia, precisão e revocação), como se pode observar na Tabela 18. Além disso, a boa relação entre precisão e acurácia mostra que o classificador apresentou poucos falsos positivos e falsos negativos. O k-NN obteve o segundo melhor desempenho, entretanto, não é um classificador adequado para implementação em um microcontrolador, pois depende de uma busca por todo o conjunto de dados de treinamento, o que pode implicar grande tempo de processamento.

Ainda em comparação com os demais classificadores desenvolvidos, a Hierarquia de Perceptrons obteve desempenho superior ao outro classificador neural desenvolvido, a rede MLP. Por isso, nos limites deste trabalho, o desempenho do primeiro mostrou-se bastante satisfatório, dada a complexidade e o poder de aquisição de aprendizado das redes MLP.

Tabela 18 - Desempenho dos classificadores.

Classificador	Acurácia	Precisão	Revocação
MLP	85,47%	88,86%	88,15%
MLP com seleção de atributos	85,54%	88,49%	88,26%
Hierarquia de Perceptrons	89,11%	91,45%	90,76%
Árvore de decisão	82,05%	84,31%	81,54%
Árvore de decisão com seleção de atributos	84,71%	87,22%	87,05%
k-NN	88,62%	91,32%	90,26%
k-NN com seleção de atributos	88,55%	90,52%	90,22%
Naive Bayes	83,94%	86,57%	86,39%
Naive Bayes com seleção de atributos	83,87%	87,11%	86,13%

6.1.7. Classificador embarcado no dispositivo vestível

O classificador neural hierárquico baseado em Perceptrons apresentou o melhor desempenho na classificação *off-line* dos dados coletados, e foi, então, selecionado para ser embarcado no dispositivo vestível para classificação *on-line*. Para avaliação do desempenho do classificador embarcado no dispositivo, realizou-se um procedimento de testes semelhante àquele realizado para coleta das amostras.

Pediu-se a um grupo de quatro indivíduos (S_1 , S_2 , S_3 e S_4), com idade média de 26,25 anos ($\pm 1,26$), sendo todos do sexo masculino, que realizassem cada uma das seis atividades que se desejava classificar, por um período em torno de 30 segundos, utilizando o dispositivo vestível na cintura. Dos participantes, apenas o sujeito S_3 participou da coleta de dados para treinamento do classificador. O dispositivo vestível foi programado com o *firmware* descrito na Seção 4.3 para executar o processo de HAR, descrito na Seção 5.2, com o classificador Hierarquia de Perceptrons.

Um aplicativo móvel foi utilizado para coletar as informações de atividade realizada pelo usuário e de atividade reconhecida pelo classificador, e armazená-las na memória. Ao fim dos testes, os dados contendo as informações de atividades realizadas e reconhecidas foram transferidos para um computador para avaliação do desempenho do classificador.

A Tabela 19 apresenta os resultados do desempenho do classificador embarcado no dispositivo vestível, em termos de acurácia, precisão e revocação. Para os três primeiros participantes, os resultados foram considerados bons, em relação ao desempenho do classificador *off-line*, visto que a classificação *on-line* pode conter amostras com características que não foram aprendidas pelo classificador. Isso ocorre principalmente devido a três fatores: características físicas de postura e de movimento diferentes entre as pessoas; amostras espúrias; e erros relacionados aos cálculos efetuados no microcontrolador durante o processo de extração de características e normalização dos dados.

Tabela 19 - Desempenho do classificador embarcado no dispositivo.

Participante	Acurácia	Precisão	Revocação
S ₁	91,80%	93,31%	90,99%
S ₂	83,66%	89,51%	84,35%
S ₃	82,73%	86,53%	83,20%
S ₄	55,97%	54,20%	59,96%
Média	77,76%	82,59%	78,63%
Média excluindo S ₄	86,06%	89,78%	86,18%

Entretanto, para o participante S₄, o desempenho do classificador embarcado foi bastante insatisfatório em relação à classificação das atividades dinâmicas. Como mostra a matriz de confusão do sujeito S₄ (Tabela 20), as atividades estáticas foram identificadas com 100% de acurácia, entretanto, entre as atividades dinâmicas “andando”, “subindo escadas” e “descendo escadas”, o classificador classificou a

atividade realizada sempre como “subindo escadas”. Esse fato indica que a coleta de dados para treinamento com um pequeno número de pessoas implicou uma falha na capacidade de generalização do classificador, requerendo que se processe o treinamento com uma base de dados extraídos de um maior número de indivíduos.

Tabela 20 - Matriz de confusão do participante S₄.

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
Atividades classificadas	Sentado	100,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Em pé	0,00%	100,00%	0,00%	0,00%	0,00%	0,00%
	Andando	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Subindo	0,00%	0,00%	100,00%	100,00%	100,00%	40,21%
	Descendo	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Correndo	0,00%	0,00%	0,00%	0,00%	0,00%	59,79%

Considerando apenas o domínio em que o classificador implementado no dispositivo foi capaz de adquirir conhecimento, obteve-se uma precisão satisfatória (89,78%), próxima à precisão do mesmo classificador *off-line* (91,45%). Para o participante S₁, o desempenho foi superior ao da Hierarquia de Perceptrons *off-line*, mostrando que é possível aplicar de forma eficiente o classificador desenvolvido em um sistema embarcado, e obter informações em tempo real, desde que seja diversificado o conjunto de treinamento com amostras de um grande número de indivíduos. A Tabela 21 apresenta a matriz de confusão média do classificador, excluindo o participante S₄. Outros resultados dos testes *on-line* encontram-se no Apêndice B.

Tabela 21 - Matriz de confusão dispensando o participante S4.

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
Atividades classificadas	Sentado	100,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Em pé	0,00%	100,00%	0,00%	2,27%	0,97%	0,00%
	Andando	0,00%	0,00%	75,18%	32,46%	5,81%	1,39%
	Subindo	0,00%	0,00%	18,94%	58,89%	1,31%	7,52%
	Descendo	0,00%	0,00%	5,88%	6,39%	91,90%	0,00%
	Correndo	0,00%	0,00%	0,00%	0,00%	0,00%	91,09%

6.1.8. Comparação com outros trabalhos

Apesar de sua simples implementação, voltada para um sistema embarcado, o classificador desenvolvido neste trabalho alcançou acurácia comparável à de outros sistemas de HAR encontrados na literatura, semelhantes ao proposto neste trabalho, como mostra a Tabela 22. Incluíram-se na comparação propostas que tinham como objetivo classificar atividades semelhantes às desse trabalho, e que utilizaram um ou, no máximo, dois acelerômetros para monitoramento da pessoa.

Alguns dos trabalhos realizam a classificação em tempo real, porém ou em um computador, ou em um *smartphone*. O grande diferencial do presente trabalho é a implementação do classificador no dispositivo vestível, o que exigiu que esse fosse de simples implementação. Portanto, para comparação, também se incluiu na Tabela 22 a acurácia obtida do classificador *on-line* proposto, excluindo o sujeito S4. Quando equiparado com os demais trabalhos, percebe-se que o sistema de HAR embarcado desenvolvido tem potencial para operar com bom desempenho, desde que seja realizado um treinamento que garanta maior aquisição de conhecimento pela arquitetura neural e, conseqüentemente, maior capacidade de generalização.

Tabela 22- Comparação com outros trabalhos.

Classificador	Processamento	Nº de atividades		Nº de usuários	Acurácia	Referência
		Estáticas	Dinâmicas			
Hierarquia de Perceptrons <i>off-line</i>	Off-line	2	4	5	89,11%	Proposto neste trabalho
Hierarquia de Perceptrons embarcado	Dispositivo vestível	2	4	3	86,06%	Proposto neste trabalho
Árvore de Decisão	<i>Smartphone</i>	1	4	15	82,73%	FAN; WANG; WANG, 2013
k-NN modificado	<i>Smartphone</i>	2	2	4	92,00%	PAUL; GEORGE, 2015
SVM modificado	<i>Smartphone</i>	3	3	30	89,00%	ANGUITA et al., 2012
SVM	<i>Smartphone</i>	3	3	10	89,59%	TRAN; PHAN, 2016
MLP	Off-line	2	3	49	83,00%	VRIES et al., 2010
MLP	Off-line	2	3	25	86,20%	LUBINA; RUDZKI, 2015
MLP	Computador	3	5	10	84,80%	LEE et al., 2010

6.2. MONITORAMENTO DE ATIVIDADES

Esta seção apresenta os resultados dos testes realizados para validação das abordagens A_2 e A_3 , que tratam do monitoramento remoto da intensidade de atividades realizadas pelo usuário, utilizando o dispositivo vestível desenvolvido neste trabalho.

6.2.1. Desvio padrão da aceleração – Abordagem A_2

Com o objetivo de validar o sistema proposto pela abordagem A_2 , o autor deste trabalho utilizou o dispositivo vestível como uma pulseira, continuamente por algumas horas, em duas situações: durante o dia realizando atividades do cotidiano e à noite

durante o sono. Os testes foram realizados da forma como foi descrita a operação da abordagem A₂, na Seção 4.1.2

Em cada teste, os dados foram coletados pelo dispositivo vestível, e, ao fim da coleta, utilizando o aplicativo móvel desenvolvido, o usuário transferiu os dados para o *smartphone* e os enviou por e-mail para ser executado pelo *software* de análise. A Figura 47 mostra os resultados do primeiro teste, com os dados coletados, por duas horas, exibidos no *software* desenvolvido para análise dos dados. O gráfico apresenta o desvio padrão médio da aceleração a cada minuto.

O profissional responsável pela análise dos dados pode escolher outras opções para o intervalo de apresentação dos dados no menu à esquerda do gráfico. Para exemplificar o uso da opção por intervalo de 15 minutos, a Figura 48 apresenta os mesmos dados coletados, porém com o cálculo da média a cada 15 minutos de dados, realizada pelo *software*.

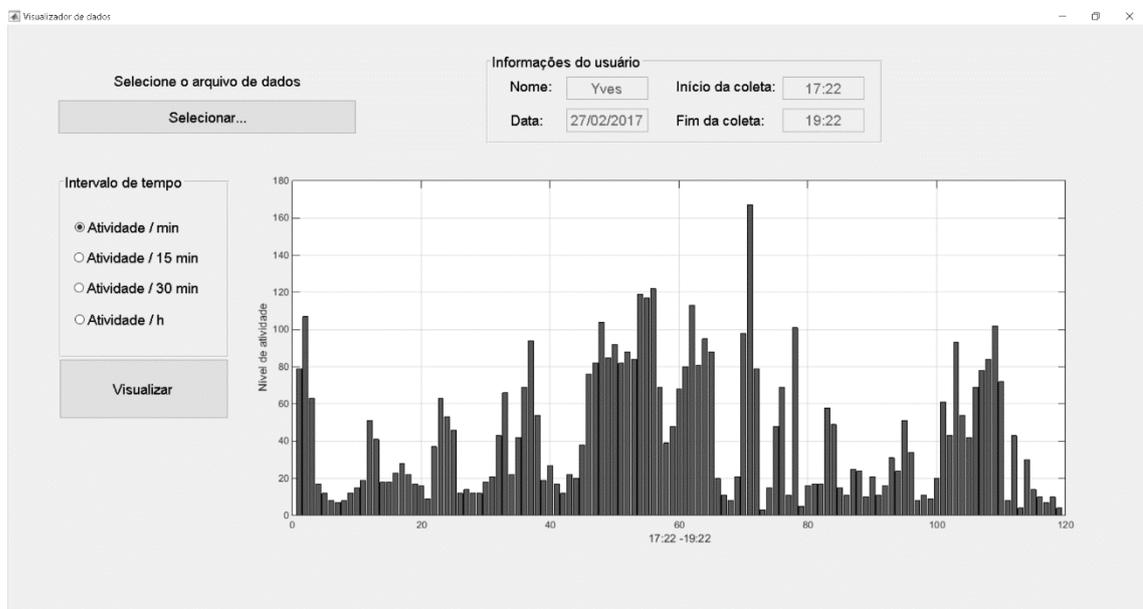


Figura 47 - Dados coletados durante o dia (informação por minuto).

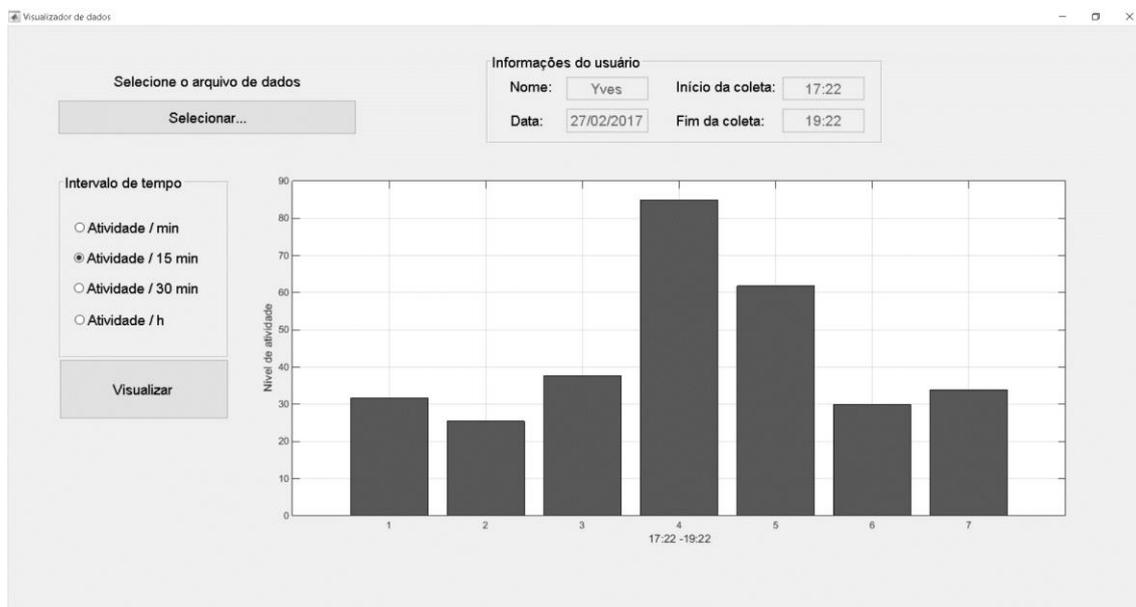


Figura 48 - Dados coletados durante a noite (informação por 15 minutos)

A Figura 49 mostra os resultados do segundo teste, com os dados coletados por três horas e 45 minutos continuamente durante o sono. O gráfico apresenta o desvio padrão médio da aceleração a cada minuto, coletada pelo dispositivo vestível. Já na Figura 50, os mesmos dados são apresentados com a média calculada a cada intervalo de 15 minutos.

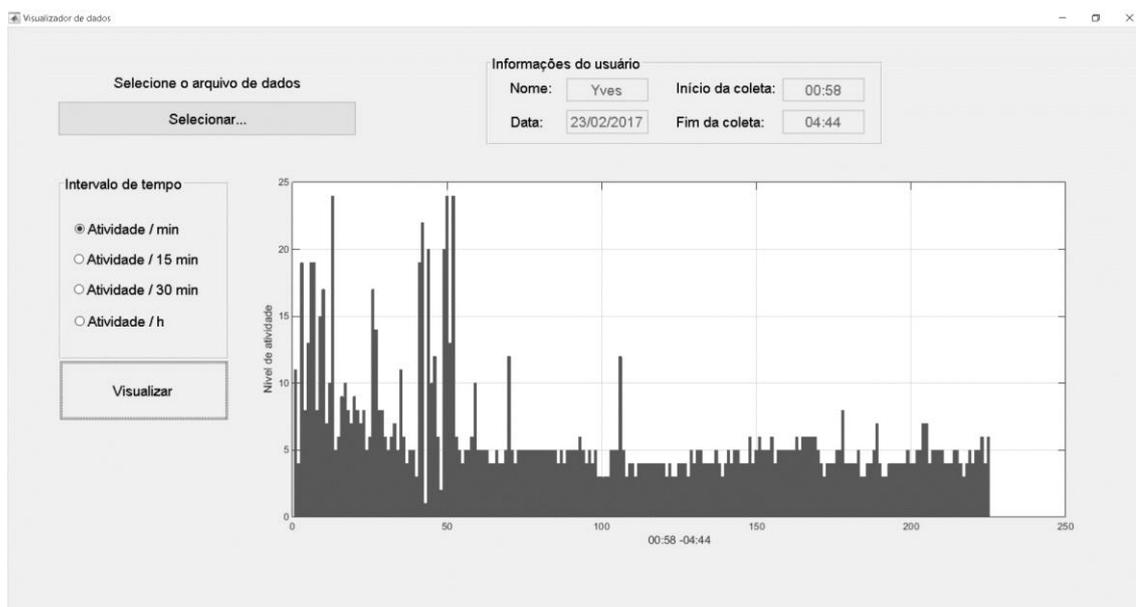


Figura 49 - Dados coletados durante o sono (informação por minuto).

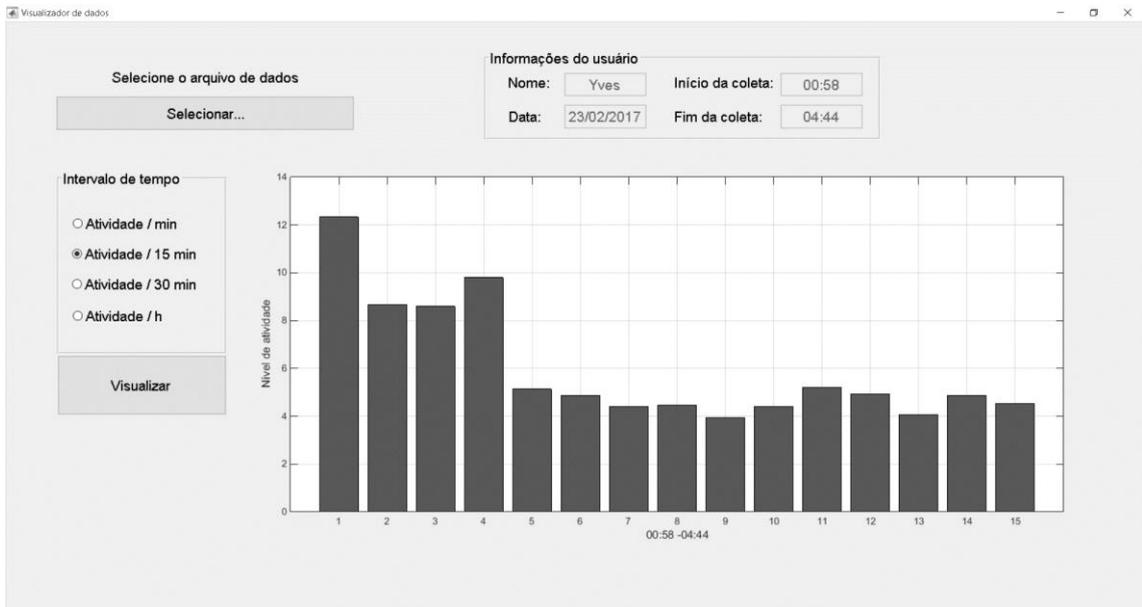


Figura 50 - Dados coletados durante o sono (informação por 15 minutos).

É importante ressaltar que a coleta do desvio padrão da aceleração é uma abordagem que ainda deve ser validada para ser utilizada como monitor de intensidade de atividades realizadas pelo usuário. Neste trabalho, construiu-se o sistema para monitorar remotamente esse parâmetro, e pretende-se aplicar o sistema em um grupo de sujeitos para avaliação da correlação entre o parâmetro e as atividades relatadas pelos participantes no teste.

O uso do dispositivo vestível no punho, como uma pulseira, o torna bastante “invisível” pelo usuário, e isso traz grandes vantagens, considerando que seu uso no sistema proposto deve ser contínuo. No entanto, deve-se destacar que o movimento do braço durante atividades rotineiras, como escovar os dentes, pentear os cabelos e cortar alimentos, podem implicar um desvio padrão grande, quando comparado com outras atividades que, a princípio, tem maior intensidade, como caminhar e subir ou descer escadas.

Para fazer uma breve análise do problema descrito, coletou-se o módulo da aceleração e o desvio padrão com um indivíduo realizando as seguintes atividades: em repouso, digitando no computador, escovando os dentes, andando e correndo. O gráfico da Figura 51 mostra que o desvio padrão foi realmente baixo, quando em repouso, como esperado, e bastante elevado quando o usuário estava correndo. Entre

as outras atividades, destaca-se que ao escovar os dentes, o desvio padrão calculado foi superior àquele quando o usuário estava andando. Portanto, no contexto desta abordagem (A_2), deve-se levar em consideração alguns fatores para evitar que falsos positivos indiquem alta intensidade de atividade física.

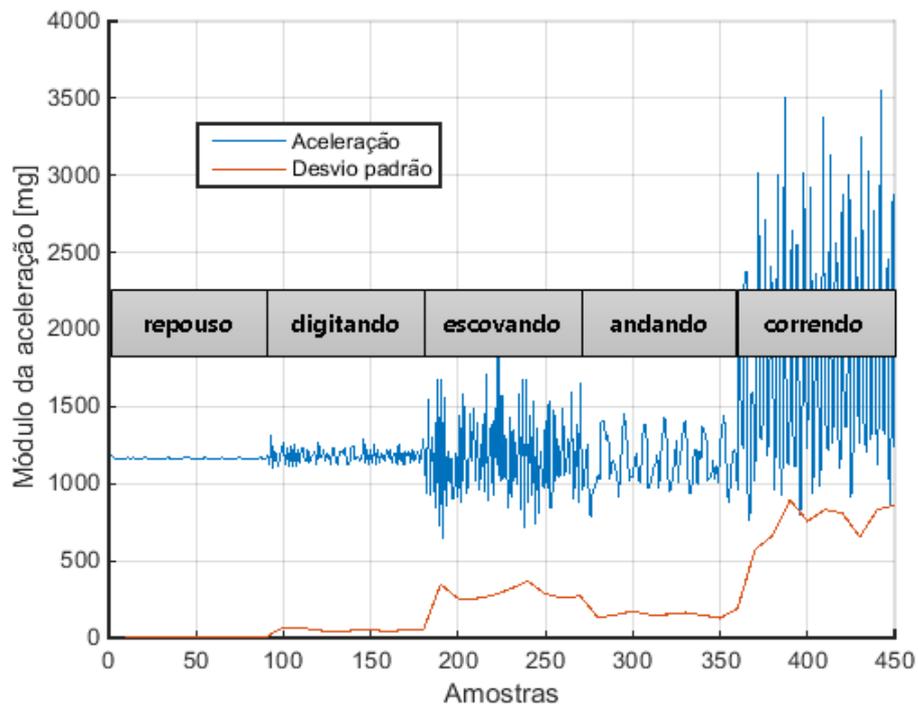


Figura 51 - Desvio padrão da aceleração por atividade.

6.2.2. Contador de passos – Abordagem A_3

Um teste preliminar verificou o desempenho do algoritmo contador de passos. Inicialmente, o usuário do teste caminhou por um minuto com o dispositivo vestível, e os dados foram analisados para definição do limiar L , utilizado no algoritmo contador de passos descrito na Seção 5.3.2. Na sequência, realizaram-se cinco testes para verificação da acurácia do algoritmo. O usuário executou em cinco repetições, uma sequência de 20 passos, andando e correndo. A Tabela 23 mostra o número de passos executados e o número de passos medidos pelo algoritmo. Nota-se que, quando configurado para um determinado usuário, o algoritmo se comporta satisfatoriamente, podendo ser utilizado no teste de longa duração para validar o sistema de monitoramento remoto proposto. Deve-se ressaltar que o algoritmo, no

estágio atual do trabalho, não lida com falsos positivos provocados por aceleração ao usuário ao se sentar ou se levantar rapidamente, retirar o cinto, entre outras.

Tabela 23 - Desempenho do algoritmo contador de passos.

Teste	Andando			Correndo		
	Passos executado	Passos medidos	Desvio	Passos executado	Passos medidos	Desvio
1	20	20	0,00%	20	20	0,00%
2	20	21	5,00%	20	20	0,00%
3	20	20	0,00%	20	20	0,00%
4	20	22	10,00%	20	21	5,00%
5	20	20	0,00%	20	21	5,00%
Média	20	20,6	3,00%	20	20,4	2,00%

Para validação da estrutura de monitoramento remoto com o contador de passos, realizou-se um teste similar ao da abordagem A₂, com o dispositivo vestível utilizado como um cinto. O dispositivo foi utilizado por 3 horas e 26 minutos pelo próprio autor do trabalho, com o algoritmo contador de passos embarcado no dispositivo, e, posteriormente, os dados foram enviados via e-mail para o responsável pela análise dos dados. Para validação do sistema de monitoramento remoto, o algoritmo contador de passos foi configurado para o usuário que testou o sistema. Futuramente, com a validação do sistema proposto, pretende-se implementar um algoritmo contador de passos adaptativo às características do usuário, para que o sistema possa ser testado por mais pessoas.

A Figura 52 apresenta o gráfico dos dados coletados exibido pelo *software* desenvolvido, mostrando o número de passos executados por minuto pelo usuário ao longo de três horas e 26 minutos. Já a Figura 53 mostra a média do número de passos executados a cada 15 minutos.

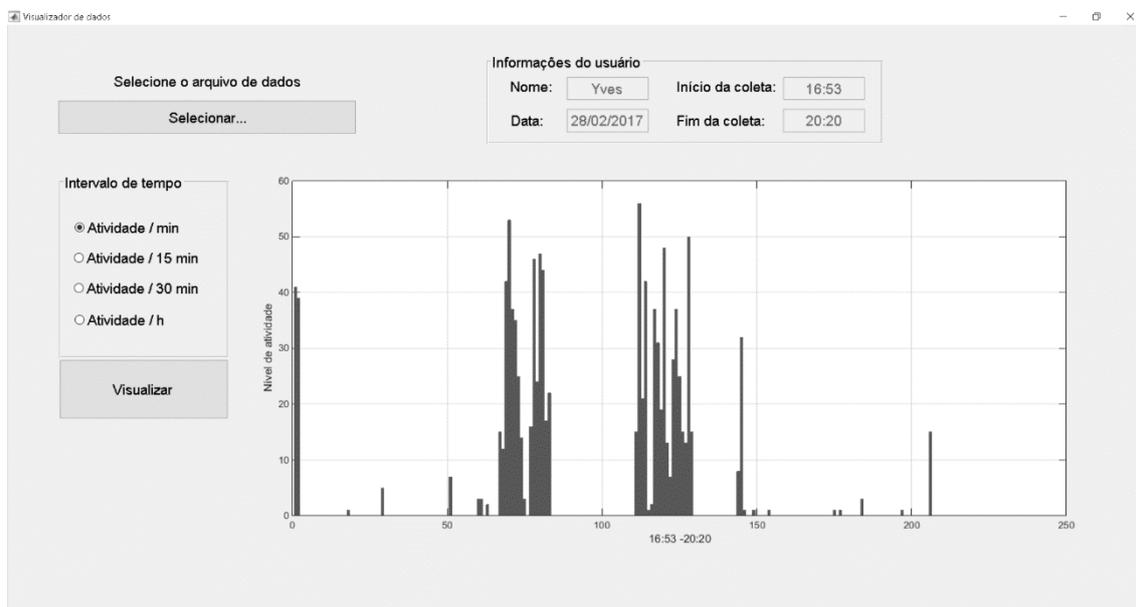


Figura 52- Número de passos por minuto coletados ao longo do dia.

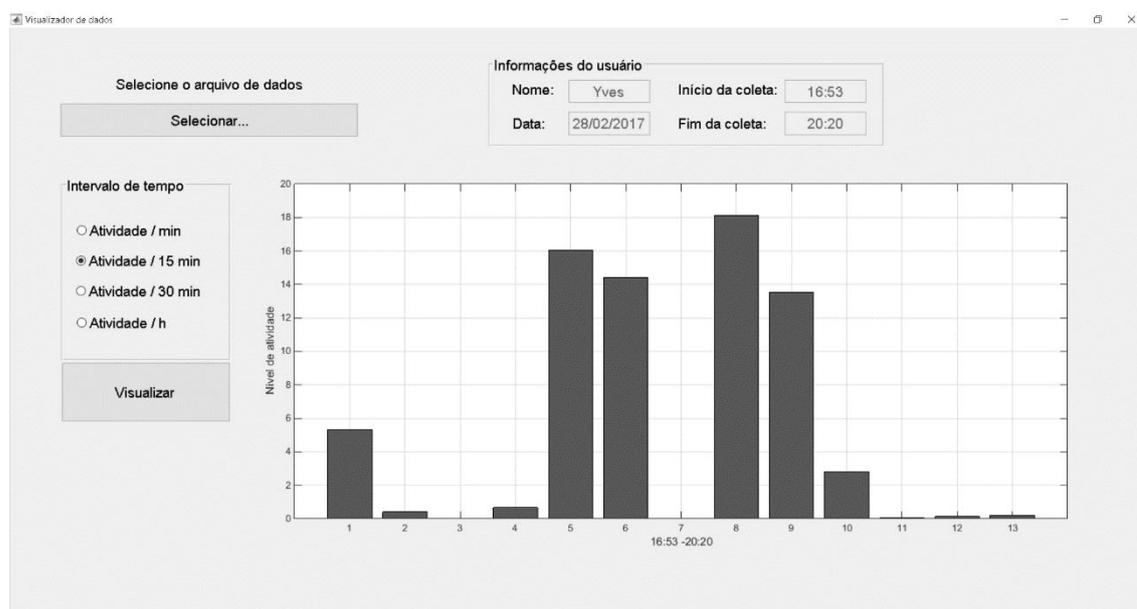


Figura 53 - Média do número de passos por 15 minutos.

7. CONCLUSÕES

Este trabalho apresentou o desenvolvimento de um sistema de Reconhecimento de Atividades Humanas (HAR) e de monitoramento remoto com o uso de um dispositivo vestível, um aplicativo móvel e um *software* para análise dos dados. O trabalho foi dividido em três abordagens, sendo a primeira delas um sistema de HAR de seis diferentes atividades, com o classificador embarcado no dispositivo. As duas últimas abordagens tratam de um sistema de monitoramento remoto de intensidade de atividades realizadas pelo usuário, com transferência dos dados coletadas por e-mail para análise em um *software* de computador.

Inicialmente, apresentou-se o desenvolvimento do protótipo desenvolvido para as três abordagens, incluindo o *hardware*, os *firmwares* e a montagem do protótipo. O circuito eletrônico funcionou de forma satisfatória, com exceção da bateria, a qual se mostrou inadequada para o protótipo no estágio atual. Deve-se investir em redução ainda maior do consumo energético do circuito, ou na seleção de uma bateria de maior capacidade e com opção de recarga, se necessário.

Na abordagem A₁, o usuário utiliza o dispositivo vestível desenvolvido, como um cinto na cintura, e um algoritmo classificador embarcado no dispositivo reconhece a atividade executada e a envia para o *smartphone* do usuário. Apresentou-se o processo completo de reconhecimento de atividades, incluindo a etapa de classificação, na qual foram desenvolvidos diferentes algoritmos para serem comparados. O algoritmo classificador vencedor, a Hierarquia de Perceptrons, foi embarcado no dispositivo vestível para classificação *on-line*. Esse classificador apresentou resultados satisfatórios, em relação aos trabalhos semelhantes recentes, principalmente quando se considera a sua simplicidade de implementação.

Entretanto, os testes *on-line* indicaram a necessidade de um processo de treinamento com dados coletados de um maior número de indivíduos, visando maior capacidade de generalização. O objetivo dessa abordagem é atuar como um sistema base nas aplicações de acompanhamento e prevenção de doenças crônicas, em desenvolvimento no NTA-UFES.

Na abordagem A₂, o sistema de monitoramento remoto desenvolvido armazena os dados do desvio padrão da aceleração medida pelo dispositivo vestível desenvolvido, o qual é utilizado como uma pulseira. O objetivo é monitorar a intensidade das atividades realizadas pelo usuário ao longo do dia. Neste trabalho, por meio de teste com uma pessoa, validou-se o modelo do sistema implementado, desde a coleta dos dados continuamente durante algumas horas, passando pelo aplicativo móvel, até o envio por e-mail para análise dos dados. Os dados coletados foram apresentados graficamente como resultados do teste. Os próximos passos devem ser em direção ao estudo da correlação entre o desvio padrão da aceleração e as atividades praticadas pelo usuário, de forma a avaliar se aquele parâmetro pode ser utilizado com essa função na aplicação de monitoramento de TAB, em desenvolvimento no NTA-UFES.

A abordagem A₃ também trata de um sistema de monitoramento remoto, no entanto, neste caso, o parâmetro monitorado é o número de passos executados pelo usuário ao longo do dia. Nessa abordagem, o usuário utiliza o dispositivo vestível em um cinto. Para validar o sistema, um simples algoritmo contador de passos foi implementado e embarcado no dispositivo para identificar e contar o número de passos, e um voluntário utilizou o dispositivo por algumas horas para coleta dos dados. Os dados coletados foram apresentados graficamente como resultados do teste. Futuramente, essa abordagem será empregada como ferramenta auxiliar de monitoramento nas aplicações em desenvolvimento no NTA-UFES. Entretanto, deve-se primeiro investir em tornar o algoritmo contador de passos mais robusto e adaptativo para diferentes pessoas.

7.1. CONTRIBUIÇÕES

As principais contribuições do presente trabalho são:

- Desenvolvimento de um protótipo portátil e versátil de reconhecimento de atividades humanas e monitoramento remoto, dotado de componentes de baixo consumo energético e com tecnologia de comunicação Bluetooth Low Energy, o qual pode ser utilizado em um cinto ou como uma pulseira.

- Desenvolvimento de um classificador neural hierárquico baseado apenas em Perceptrons simples, com o qual se obteve desempenho superior ao de classificadores mais complexos, utilizados em trabalhos semelhantes a este.
- Utilização do sistema inteligente de HAR embarcado no dispositivo vestível, tornando possível o monitoramento das atividades realizadas por uma pessoa ao longo do dia, sem a necessidade de um *smartphone* ou de um computador para processar os dados.
- Possibilidade de se monitorar as atividades de forma verdadeiramente contínua ao longo do dia, com o uso do dispositivo vestível desenvolvido, visto que muitos trabalhos usam os sensores do *smartphone* do usuário, exigindo que este esteja sempre junto ao corpo da pessoa.
- Pela mesma razão do item anterior, com o dispositivo utilizado como uma pulseira, é possível monitorar a qualidade do sono do usuário, parâmetro importante nas aplicações de monitoramento de pessoas com TAB.

7.2. PUBLICAÇÕES CIENTÍFICAS

Durante da realização desta pesquisa, as seguintes publicações científicas foram realizadas:

- COELHO, Y. L.; BASTOS-FILHO; T. F. A Bipolar Disorder Monitoring System Based on Wearable Device and Smartphone. IFAC-PapersOnLine, v. 49, n. 30, p. 216-220, 2016.
- COELHO, Y. L.; BISSOLI, A. L. C.; SIME, M. M.; BASTOS-FILHO, T. F. Um Novo Sistema de Comunicação Aumentativa e Alternativa Baseado em Rastreamento do Olhar. In: XXV Congresso Brasileiro de Engenharia Biomédica (CBEB), Foz do Iguaçu, 2016.
- BISSOLI, A. L. C.; SIME, M. M.; COELHO, Y. L.; BASTOS-FILHO, T. F. Avaliação de Usabilidade e Desempenho de um Novo Sistema de Comunicação Aumentativa e Alternativa por Rastreamento do Olhar. In: XXI Congresso Brasileiro de Automática (CBA), Vitória, 2016.
- BISSOLI, A. L. C.; COELHO, Y. L.; BASTOS-FILHO, T. F. A System for Multimodal Assistive Domotics and Augmentative and Alternative

Communication. In: International Conference on Pervasive Technologies Related to Assistive Environments (PETRA), Corfu Island, 2016.

- COELHO, Y. L.; BISSOLI, A. L. C.; SIME, M. M.; BASTOS-FILHO, T. F. CAApp: Um Aplicativo Móvel de Comunicação Aumentativa e Alternativa para Pessoas com Deficiência Motora Severa. In: XV Workshop de Informática Médica - XXXV Congresso da Sociedade Brasileira de Computação (CSBC), Recife, 2015.

7.3. TRABALHOS FUTUROS

Em relação ao protótipo construído, pretende-se estudar a possibilidade de redução de seu consumo energético, buscando os pontos críticos a esse respeito no *hardware* e nos *firmwares* desenvolvidos. Também deve-se estudar a possibilidade e a necessidade de uso de outro microcontrolador, com mais recursos disponíveis, desde que possua características de baixo consumo energético. Além disso, pretende-se adicionar ao *hardware* outros sensores, como giroscópio, e implementar fusão de dados no *firmware*, para buscar melhor desempenho do sistema de classificação de atividades.

No contexto do sistema de HAR, pretende-se expandir a coleta de dados para treinamento do classificador, formando uma base de dados com informações provenientes de um grande número de pessoas diferentes, buscando garantir maior capacidade de generalização do classificador.

Sobre as abordagens de monitoramento remoto de atividades, pretende-se testar o sistema de monitoramento pelo parâmetro desvio padrão com diferentes pessoas, para avaliar a correlação desse parâmetro com a intensidade das atividades realizadas pela pessoa ao longo do dia. Já para o monitoramento por número de passos executados, deve-se, inicialmente, investir na melhoria do algoritmo contador de passos, buscando torná-lo adaptativo e robusto, para que o teste de monitoramento contínuo possa ser realizado com diferentes pessoas.

REFERÊNCIAS

- ANGUITA, D. et al. Energy Efficient Smartphone-Based Activity Recognition using Fixed-Point Arithmetic. **JUCS - Journal of Universal Computer Science**, v. 19, n. 9, p.1295-1314, 1 maio 2013.
- APPELBOOM, G. et al. The promise of wearable activity sensors to define patient recovery. **Journal of Clinical Neuroscience**, v. 21, n. 7, p.1089-1093, jul. 2014.
- ATTAL, F. et al. Physical Human Activity Recognition Using Wearable Sensors. **Sensors**, v. 15, n. 12, p.31314-31338, 11 dez. 2015.
- AVCI, A.; BOSCH, S.; MARIN-PERIANU, M. Activity Recognition Using Inertial Sensing for Healthcare, Wellbeing and Sports Applications: A Survey. **2010 23rd International Conference on Architecture of Computing Systems (ARCS)**, p.1-10, 22 fev. 2011.
- AWAIS, M.; PALMERINI, L.; CHIARI, L. Physical activity classification using body-worn inertial sensors in a multi-sensor setup. **2016 IEEE 2nd International Forum on Research and Technologies for Society and Industry Leveraging a Better Tomorrow (RTSI)**, [s.l.], p.1-4, set. 2016.
- BASSI, A; BAUER, M.; FIEDLER, M.; KRAMP, T.; KRANENBURG, R.; LANGE, S.; MEISSNER, S. **Enabling things to talk: Designing IoT solutions with the IoT Architectural Reference Model**, 2013.
- BEIWINKEL, T. et al. Using Smartphones to Monitor Bipolar Disorder Symptoms: A Pilot Study. **JMIR Mental Health**, v. 3, n. 1, 6 jan. 2016.
- BILLIET, L. et al. Accelerometry-Based Activity Recognition and Assessment in Rheumatic and Musculoskeletal Diseases. **Sensors**, [s.l.], v. 16, n. 12, p.2151, 16 dez. 2016.
- BLUE CREATION. **BC118**. Disponível em: <http://www.blue-creation.com/product_info.php?products_id=64>. Acesso em: 10 jan. 2017.

BLUETOOTH. **Bluetooth Core Specification.** Disponível em: <<https://www.bluetooth.com/specifications/bluetooth-core-specification>>. Acesso em: 10 jan. 2017.

BRAAM, K. et al. Wristband Vital: A wearable multi-sensor microsystem for real-time assistance via low-power Bluetooth link. **2015 IEEE 2nd World Forum on Internet of Things (WF-IoT)**, [s.l.], p.1-5, dez. 2015.

BREIMAN, L., J. H. FRIEDMAN, R. A. OLSHEN, AND C. J. STONE. 1984. Classification and regression trees. Monterey, Calif., U.S.A.: Wadsworth, Inc.

CATARINUCCI, L.; COLELLA, R.; TARRICONE, L. Integration of RFID and sensors for remote healthcare. **2010 3rd International Symposium on Applied Sciences in Biomedical and Communication Technologies (ISABEL 2010)**, Rome, p.1-1, nov. 2010.

CHIAVEGATTO FILHO, A. D. P. Uso de big data em saúde no Brasil: perspectivas para um futuro próximo. *Epidemiologia e Serviços de Saúde*, v. 24, n. 2, p. 325-332, 2015. **Epidemiologia e Serviços de Saúde**, v. 24, n. 2, p.325-332, jun. 2015.

COLLINS, P. M. et al. Interpreting behaviors from accelerometry: a method combining simplicity and objectivity. **Ecology and Evolution**, v. 5, n. 20, p. 4642-4654, out. 2015.

CORNACCHIA, M. et al. A Survey on Activity Detection and Classification Using Wearable Sensors. **IEEE Sensors Journal**, v. 17, n. 2, p.386-403, 15 jan. 2017.

CYPRESS. **CYBLE-012012-10.** Disponível em: <<http://www.cypress.com/documentation/datasheets/cyble-012011-00cyble-012012-10-ez-bletm-proctm-module>>. Acesso em: 10 jan. 2017.

DEEN, M. J. Information and communications technologies for elderly ubiquitous healthcare in a smart home. **Personal And Ubiquitous Computing**, v. 19, n. 3-4, p.573-599, 26 jun. 2015.

FAN, L.; WANG, Z.; WANG, H. Human Activity Recognition Model Based on Decision Tree. **2013 International Conference on Advanced Cloud and Big Data**, [s.l.], p.64-68, dez. 2013.

FAROOQ, M.; SAZONOV, E. A Novel Wearable Device for Food Intake and Physical Activity Recognition. **Sensors**, v. 16, n. 7, p.1067, 11 jul. 2016.

FU, Y.; LIU, J. System Design for Wearable Blood Oxygen Saturation and Pulse Measurement Device. **Procedia Manufacturing**, v. 3, p.1187-1194, 2015.

GAO, L.; BOURKE, A.; NELSON, J. Evaluation of accelerometer based multi-sensor versus single-sensor activity recognition systems. **Medical Engineering & Physics**, v. 36, n. 6, p.779-785, jun. 2014.

GARBARINO, M. et al. Empatica E3 - A wearable wireless multi-sensor device for real-time computerized biofeedback and data acquisition. **Proceedings of the 4th International Conference on Wireless Mobile Communication and Healthcare**, [s.l.], p.39-42, nov. 2014.

GARCEZ-LEME, L. E.; LEME, M. D. Costs of elderly health care in Brazil: challenges and strategies. **Medical Express (São Paulo, online)**, São Paulo, v. 1, n. 1, p. 3-8, 2014.

GOMEZ, C.; OLLER, J.; PARADELLS J. Overview and evaluation of Bluetooth low energy: An emerging low-power wireless technology, **Sensors**, vol. 12, no. 9, pp. 11 734–11 753, 2012.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Pearson: New Jersey, 2008.

IBGE. **Síntese de Indicadores Sociais**: uma análise das condições de vida da população brasileira, 2015.

ITEAD. **HM-10 module**. Disponível em: <<https://www.itead.cc/serial-port-ble-module-master-slave-hm-10.html>>. Acesso em: 10 jan. 2017.

IZUMI, S. et al. A Wearable Healthcare System with a 13.7 uA Noise Tolerant ECG Processor. **IEEE Transactions on Biomedical Circuits and Systems**, v. 9, n. 5, p.733-742, out. 2015.

JAMISON K. R.; AKISKAL H. S. Medication compliance in patients with bipolar disorder. **Psychiatr Clin North Am**, v. 6 n. p. 175-192, mar. 1983.

JOHANSSON, A.; SHEN, W.; XU, Y. An ANT Based Wireless Body Sensor Biofeedback Network for Medical E-Health Care. **2011 7th International Conference on Wireless Communications, Networking and Mobile Computing**, Wuhan, p.1-5, set. 2011.

KANG, D. W. et al. Real-time elderly activity monitoring system based on a tri-axial accelerometer. **Disability and Rehabilitation: Assistive Technology**, v. 5, n. 4, p. 247–253, jul. 2010.

KHAN, A. et al. Optimising sampling rates for accelerometer-based human activity recognition. **Pattern Recognition Letters**, v. 73, p.33-40, abr. 2016.

KIM, E.; HELAL, S.; COOK, D. Human Activity Recognition and Pattern Discovery. **Ieee Pervasive Computing**, v. 9, n. 1, p.48-53, jan. 2010.

KUMARI, P.; MATHEW, L.; SYAL, P. Increasing trend of wearables and multimodal interface for human activity monitoring: A review. **Biosensors and Bioelectronics**, v. 90, p.298-307, abr. 2017.

LADHA, L. et al. Feature Selection Methods and Algorithms. **International Journal on Computer Science and Engineering**, v. 3, n. 5, p. 1787-1797, maio 2011.

LAERHOVEN, K.; BERLIN, E.; SCHIELE, B. Enabling Efficient Time Series Analysis for Wearable Activity Data. **2009 International Conference on Machine Learning and Applications**, [s.l.], p.392-397, dez. 2009.

LEE, M.; KHAN, A. M.; KIM, J. A single tri-axial accelerometer-based real-time personal life log system capable of activity classification and exercise information generation. **2010 Annual International Conference of the IEEE Engineering in Medicine and Biology**, Buenos Aires, p.1390-1393, ago. 2010.

LI, K.; WARREN, S. A. Wireless Reflectance Pulse Oximeter with Digital Baseline Control for Unfiltered Photoplethysmograms. **IEEE Transactions on Biomedical Circuits And Systems**, v. 6, n. 3, p.269-278, jun. 2012.

LIU, X. et al. Human Daily Activity Recognition for Healthcare Using Wearable and Visual Sensing Data. **2016 IEEE International Conference on Healthcare Informatics (ICHI)**, [s.l.], p.24-31, out. 2016.

LOBBAN, F. et al. Early warning signs checklists for relapse in bipolar depression and mania: Utility, reliability and validity. **Journal of Affective Disorders**, v. 133, n. 3, p.413-422, out. 2011.

LOPEZ-SORIANO, S.; PARRON, J. Low profile UHF RFID tag for wristbands in healthcare applications. **The 8th European Conference on Antennas and Propagation (eucap 2014)**, The Hague, 1, abr. 2014.

LUBINA, P.; RUDZKI, M. Artificial neural networks in accelerometer-based human activity recognition. **2015 22nd International Conference Mixed Design Of Integrated Circuits & Systems (MIXDES)**, Torun, p.63-68, jun. 2015.

LYMBERIS A. Smart wearable systems for personalised health management: current R&D and future challenges. **25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**, v. 4, IEEE, Cancun, pp. 3716–3719, 2003.

MACHADO, I. P. et al. Human activity data discovery from triaxial accelerometer sensor: Non-supervised learning sensitivity to feature extraction parametrization. **Information Processing & Management**, v. 51, n. 2, p.204-214, mar. 2015.

MADANIAN, S. The use of e-health technology in healthcare environment: The role of RFID technology. **2016 10th International Conference on E-commerce in Developing Countries: with focus on e-Tourism (ECDC)**, Isfahan, p.1-5, abr. 2016.

MAJUMDER, S.; MONDAL, T.; DEEN, M. Wearable Sensors for Remote Health Monitoring. **Sensors**, v. 17, n. 1, p.1-45, 12 jan. 2017.

MEGALINGAM, R. K. MediSuit: Wearable health monitoring system for elders and bed-ridden patients. **2016 10th International Conference on Intelligent Systems and Control (ISCO)**, [s.l.], p.1-6, jan. 2016.

MEHMOOD, N.Q.; CULMONE, R. An ANT Protocol Based Health Care System. In Proceedings of the 2015 IEEE 29th International Conference on Advanced Information Networking and Applications Workshops, Guwangiu, Korea, p. 193-198. mar. 2015.

MICROCHIP. **RN4020**. Disponível em: <<http://www.microchip.com/wwwproducts/en/RN4020>>. Acesso em: 10 jan. 2017.

MIRAGAYA, A. **Promoção da saúde através da atividade física**. Em COSTA, L. (Org.). Atlas do esporte no Brasil: atlas do esporte, educação física e atividades físicas de saúde e lazer no Brasil (pp. 16-28). Rio de Janeiro: CONFEF, 2006.

MITCHELL, T. M. **Machine Learning**. McGraw-Hill Science: 1997.

MORRISS, R., FAIZAL, M. A., JONES, A. P.; BOLTON, C. A., WILLIAMSON, P. R.; MCCARTHY, J. P. Interventions for helping people recognise early signs of recurrence in bipolar disorder: full review, CD004854, Cochrane Collaboration, jan. 2007.

MUNOZ-ORGANERO, M.; LOTFI, A. Human Movement Recognition Based on the Stochastic Characterisation of Acceleration Data. **Sensors**, v. 16, n. 9, p.1-16, 9 set. 2016.

NEMATI, E.; DEEN, M.; MONDAL, T. A wireless wearable ECG sensor for long-term applications. **IEEE Communications Magazine**, v. 50, n. 1, p.36-43, jan. 2012.

NUTTAITANAKUL, N.; LEAUHATONG, T. A novel algorithm for detection human falling from accelerometer signal using wavelet transform and neural network. **2015 7th International Conference on Information Technology and Electrical Engineering (ICITEE)**, Chiang Mai, p.215-220, out. 2015.

OMRE, A. H. Reducing Healthcare Costs with Wireless Technology. **Wearable and Implantable Body Sensor Networks, 2009. BSN 2009. Sixth International Workshop On**, Berkeley, p.65-70, jun. 2009.

ONU, Department of Economic and Social Affairs, Population Division. World Population Prospects: The 2015 Revision, Key Findings and Advance Tables. Working Paper No. ESA/P/WP.241, 2015.

- PANTELOPOULOS, A.; BOURBAKIS, N. G. A Survey on Wearable Sensor-Based Systems for Health Monitoring and Prognosis. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, v. 40, n. 1, p.1-12, jan. 2010.
- PAUL, P.; GEORGE, T. An effective approach for human activity recognition on smartphone. **2015 IEEE International Conference on Engineering and Technology (IECTECH)**, [s.l.], p.1-3, mar. 2015.
- PHAN, T. Improving activity recognition via automatic decision tree pruning. **Proceedings of the 2014 Acm International Joint Conference on Pervasive and Ubiquitous Computing Adjunct Publication - Ubicomp**, [s.l.], p.827-831, 2014.
- PUIATTI, A. et al. Smartphone-centred wearable sensors network for monitoring patients with bipolar disorder. **2011 Annual International Conference of The IEEE Engineering in Medicine and Biology Society**, Boston, p.3644-3647, ago. 2011.
- RAVI, N.; DANDEKAR, N.; MYSORE, P.; LITTMAN, M. L. 2005. Activity recognition from accelerometer data. **Proceedings of the 17th conference on Innovative applications of artificial intelligence (IAAI)**, v. 3. p. 1541-1546, jul. 2005.
- RIHANA, S.; MONDALAK, J. Wearable fall detection system. **2016 3rd Middle East Conference on Biomedical Engineering (MECBME)**, [s.l.], p.1-4, out. 2016.
- RODRÍGUEZ-MARTÍN, D et al. Home detection of freezing of gait using support vector machines through a single waist-worn triaxial accelerometer. **PLoS ONE** v. 12, n. 2, fev. 2017.
- RONAO, C. A.; CHO, S. Human activity recognition with smartphone sensors using deep learning neural networks. **Expert Systems with Applications**, v. 59, p.235-244, out. 2016.
- RUI, Z.; QI, L.; CHUANG, L. Design of Wireless Wearable Multi Parameter Monitoring System Based on GSM Communication. **2016 International Symposium on Computer, Consumer and Control (IS3C)**, [s.l.], p.714-717, jul. 2016.
- SAFI, K. et al. Recognition of different daily living activities using hidden Markov model regression. **2016 3rd Middle East Conference on Biomedical Engineering (mecbme)**, Beirut, p.1-4, out. 2016.

SHALEV-SHWARTZ S.; BEN-DAVID S. **Understanding Machine Learning: From Theory to Algorithms**. Cambridge University Press: New York, 2014

SHOAI B, M. et al. A Survey of Online Activity Recognition Using Mobile Phones. **Sensors**, v. 15, n. 1, p.2059-2085, 19 jan. 2015.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SPANO, E.; PASCOLI, S.; IANNACCONE, G. Low-Power Wearable ECG Monitoring System for Multiple-Patient Remote Monitoring. **IEEE Sensors Journal**, v. 16, n. 13, p.5452-5462, jul. 2016.

SUZUKI, T. et al. Wearable wireless vital monitoring technology for smart health care. **2013 7th International Symposium on Medical Information and Communication Technology (ismict)**, [s.l.], p.1-4, mar. 2013.

TENG, X. et al. Wearable Medical Systems for p-Health. **IEEE Reviews in Biomedical Engineering**, [s.l.], v. 1, p.62-74, 2008. Institute of Electrical and Electronics Engineers (IEEE).

TORRES-HUITZIL, C.; ALVAREZ-LANDERO, A. Accelerometer-Based Human Activity Recognition in Smartphones for Healthcare Services. **Springer Series in Bio-Neuroinformatics**, v. 5, p. 147-169, 2015.

TOUMPANIARIS, P. et al. A Survey for Chronic Diseases Management and the Related Sensors in the Ambient Assisted Living Environment. **International Journal of Health Research and Innovation**, v. 2, n. 1, p.65-84, maio 2014.

TRAN, D. N.; PHAN, D. D. Human Activities Recognition in Android Smartphone Using Support Vector Machine. **IEEE 7th International Conference on Intelligent Systems, Modelling and Simulation**, Bangkok, p.64-68, jan. 2016.

TSENG, K. C.; LIN, B.; LIAO, L. Development of a Wearable Mobile Electrocardiogram Monitoring System by Using Novel Dry Foam Electrodes. **IEEE Systems Journal**, v. 8, n. 3, p.900-906, set. 2014.

VICENTE, J. M. et al. Design of a wearable bio-patch for monitoring patient's temperature. **2016 38th Annual International Conference of The IEEE Engineering in Medicine and Biology Society (EMBC)**, [s.l.], p.4792-4795, ago. 2016.

VOGT, C. et al. A wearable bluetooth LE sensor for patient monitoring during MRI scans. **2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**, [s.l.], p.4975-4978, ago. 2016.

VRIES, S. I. et al. Evaluation of Neural Networks to Identify Types of Activity Using Accelerometers. **Medicine & Science in Sports & Exercise**, v. 43, n. 1, p.101-107, jan. 2011.

WANG, A. et al. A Comparative Study on Human Activity Recognition Using Inertial Sensors in a Smartphone. **IEEE Sensors Journal**, v. 16, n. 11, p.4566-4578, jun. 2016.

WORLD HEALTH ORGANIZATION. Telemedicine. Opportunities and developments in member states. Global Observatory for eHealth series, v. 2, 2010.

WU, X.; LI, S. Zigbee transmission system for wearable ECG device based on compressed sensing. **11th International Conference on Wireless Communications, Networking and Mobile Computing (wicom 2015)**, [s.l.], p.1-4, 2015.

XIE, H.; FEDDER, G. K.; SULOUFF, R. E. Accelerometers. **Comprehensive Microsystems**, p.135-180, 2008.

XU, H. et al. Wearable Sensor-Based Human Activity Recognition Method with Multi-Features Extracted from Hilbert-Huang Transform. **Sensors**, v. 16, n. 12, p.2048, 2 dez. 2016.

YAZDANSEPAS, D. et al. A Multi-featured Approach for Wearable Sensor-Based Human Activity Recognition. **2016 IEEE International Conference on Healthcare Informatics (ICHI)**, [s.l.], p.423-431, out. 2016.

YIN, Y. et al. The internet of things in healthcare: An overview. **Journal of Industrial Information Integration**, [s.l.], v. 1, p.3-13, mar. 2016.

ZUBAIR, M.; SONG, K.; YOON, C. Human activity recognition using wearable accelerometer sensors. **2016 IEEE International Conference on Consumer Electronics - Asia (ICCE-Asia)**, [s.l.], p.1-5, out. 2016.

APÊNDICE A – Redes Neurais Artificiais

Modelo de um neurônio artificial

Um modelo simples de neurônio artificial k , com seus principais elementos, é apresentado na Figura 54. Os sinais de entrada (x_1, x_2, \dots, x_m) são as variáveis de uma determinada aplicação. Os pesos sinápticos ($w_{k1}, w_{k2}, \dots, w_{km}$) ponderam as entradas e quantificam as relevâncias de cada uma. O combinador linear Σ agrega os sinais de entrada que foram ponderados.

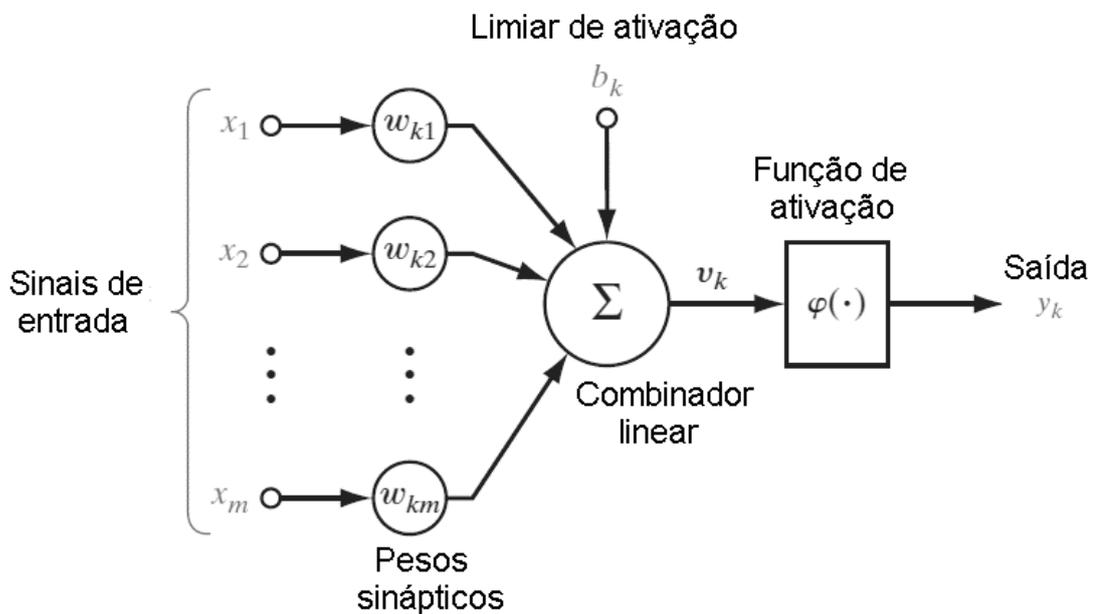


Figura 54 - Modelo de um neurônio artificial.

Fonte: Haykin (2008), p. 12, adaptado.

O limiar de ativação b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação. O potencial de ativação v_k é o resultado produzido pelo combinador linear. A função da ativação $\varphi(\cdot)$ limita a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua imagem. Por último, o sinal de saída y_k é o valor final produzido pelo neurônio. De acordo com Haykin (2008), matematicamente, um neurônio k pode ser descrito pelas seguintes equações:

$$u_k = \sum_{j=1}^m w_{k,j} x_j \quad (25)$$

$$v_k = u_k + b_k \quad (26)$$

$$y_k = \varphi(u_k + b_k) \quad (27)$$

Geralmente, define-se o intervalo normalizado da amplitude da saída de um neurônio pelo intervalo unitário fechado $[0, 1]$, ou alternativamente $[-1, 1]$. Os tipos de função de ativação mais comuns na implementação de ANN são a função degrau (Figura 55a), definida pela Equação 28, e a função logística (Figura 55b), definida pela Equação 29, sendo a o parâmetro de inclinação da função. O resultado produzido pela aplicação da função logística assume sempre valores reais entre zero e um.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (28)$$

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (29)$$

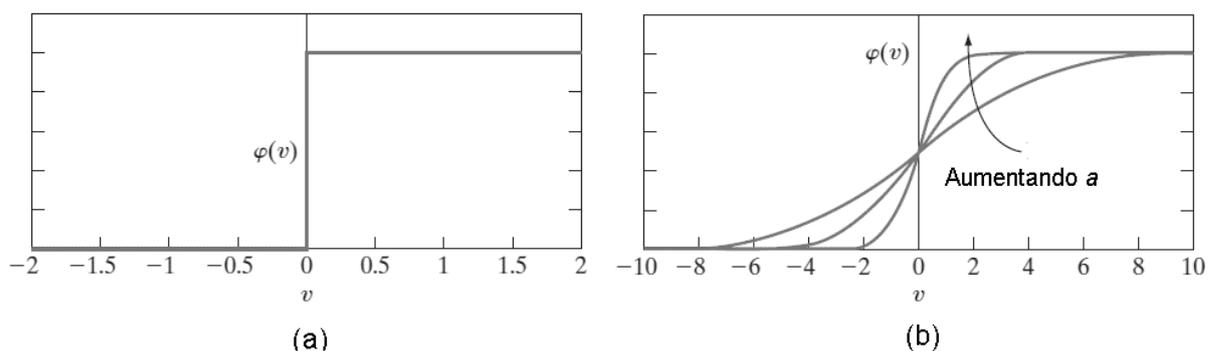


Figura 55 – Funções de ativação: a) degrau; b) logística.

Fonte: Haykin (2008), p. 13, adaptado.

Perceptron

A configuração mais elementar de uma rede neural é o Perceptron, a qual possui uma camada de entrada, e uma camada de saída composta por apenas um neurônio, com

estrutura semelhante ao neurônio artificial apresentado na Figura 54. A função de ativação $\varphi(\cdot)$ mais utilizada no Perceptron é a função degrau bipolar, uma variação da função degrau, apresentada na Equação 28. Conhecendo a definição de v , pela Equação 26, a saída do Perceptron será:

$$y = \begin{cases} 1, & \text{se } \sum_{j=1}^m w_j x_j + b \geq 0 \\ -1, & \text{se } \sum_{j=1}^m w_j x_j + b < 0 \end{cases} \quad (30)$$

Como a saída produzida pode assumir apenas dois valores diferentes, o Perceptron pode realizar classificação de padrões em apenas duas classes distintas. Com base na Equação 30, pode-se observar que a fronteira de separação entre as classes será um hiperplano definido pela Equação 31.

$$\sum_{j=1}^m w_j x_j + b = 0 \quad (31)$$

Portanto, conclui-se que o Perceptron é um classificador de padrões capaz de dividir amostras em duas classes, que sejam linearmente separáveis. A Figura 56 apresenta um exemplo da fronteira de decisão para um conjunto de amostras com duas entradas. Neste caso bidimensional, a fronteira de decisão é uma reta.

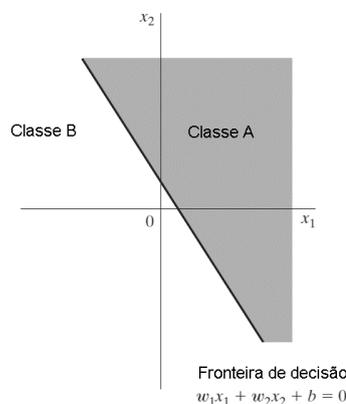


Figura 56 - Fronteira de decisão da Perceptron.

Fonte: Haykin, 2008, p. 49, adaptado.

No processo de treinamento do Perceptron, os pesos sinápticos são incrementados proporcionalmente aos valores de seus sinais de entrada, caso a saída produzida pelo neurônio seja coincidente com a saída desejada. No caso contrário, os pesos sinápticos são, então, decrementados. O processo repete-se sequencialmente para todas as amostras de treinamento, até que a saída produzida pelo Perceptron seja similar à saída desejada de cada amostra (SILVA; SPATTI; FLAUIZIO, 2010). A regra de atualização dos pesos para uma amostra i é definida pela Equação 32, sendo \mathbf{w} e \mathbf{x} , vetores de pesos sinápticos e entradas, respectivamente, η a taxa de aprendizagem do processo, n a iteração atual, d a saída desejada e y a saída obtida pelo Perceptron.

$$\mathbf{w}[n + 1] = \mathbf{w}[n] + \eta (d_i - y)\mathbf{x}_i \quad (32)$$

Perceptron de múltiplas camadas (MLP)

A rede MLP caracteriza-se pela presença de ao menos uma camada oculta de neurônios, e pelo uso de uma função de ativação não-linear e diferenciável. Os neurônios que compõem uma rede MLP são similares ao modelo apresentado na Figura 54. A camada de saída de uma rede MLP pode ser composta por mais de um neurônio, o que possibilita a classificação de um conjunto de amostras em diversas classes. A Figura 57 mostra a estrutura de uma rede MLP com duas camadas ocultas.

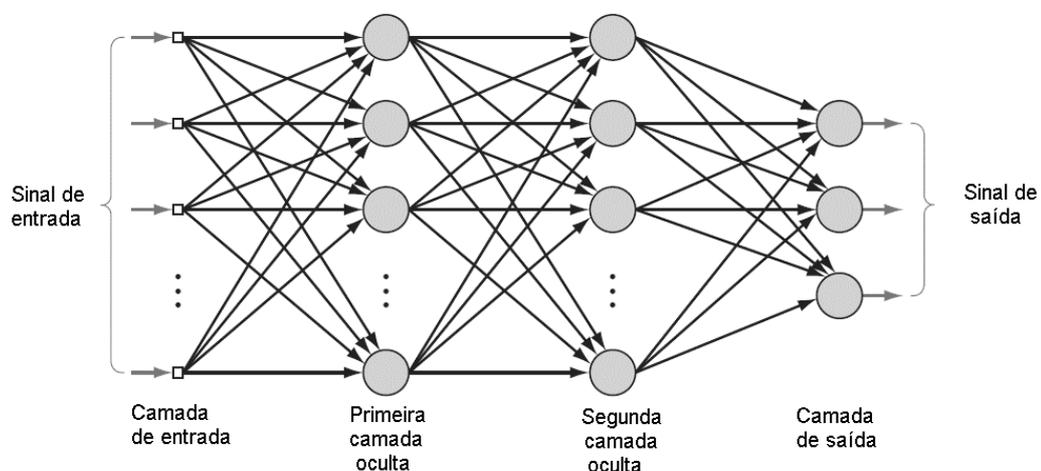


Figura 57 - Perceptron de múltiplas camadas (MLP).

Fonte: Haykin, 2008, p. 124, adaptado.

Haykin (2008) descreve que o MLP tem sido aplicado com sucesso para resolver diversos problemas complexos, por meio do seu treinamento supervisionado com um algoritmo conhecido como *backpropagation* (retropropagação). Esse algoritmo divide-se em duas etapas. A primeira delas é a propagação adiante, quando as entradas são levadas às camadas seguintes, sendo ponderadas, combinadas e processadas pela função de ativação, até a camada de saída, onde tem-se como resultado a resposta da rede para um dado conjunto de entradas. A cada iteração do processo de treinamento calcula-se o erro quadrático entre a saída obtida e a resposta esperada, definido pela Equação 33, sendo d_k a saída desejada e y_k a saída obtida do neurônio k , para a i -ésima amostra de treinamento.

$$E = \frac{1}{2} \sum_{k=1}^m [d_k(i) - y_k(i)]^2 \quad (33)$$

A segunda etapa é a retropropagação, onde ocorre o ajuste dos pesos sinápticos a partir da camada de saída em direção à camada de entrada. Em síntese, para minimizar o erro da saída, o ajuste do vetor de pesos sinápticos deve ser realizado na direção oposta ao gradiente do erro quadrático vetor. Para tal, calcula-se o gradiente local, δ_k , de cada neurônio k . O ajuste de pesos de uma camada C , para uma amostra i , é definido segundo a Equação 34.

$$\mathbf{w}_{k,i}^C[n+1] = \mathbf{w}_{k,i}^C[n] + \eta \delta_k^C y_i^{C-1} \quad (34)$$

Adicionalmente, pode-se utilizar o termo *momentum* para ponderar o quão as matrizes de pesos sinápticos foram alteradas entre duas iterações sucessivas. Quando a solução atual estiver longe da solução final, a variação na direção oposta ao gradiente da função erro quadrático entre duas iterações seguidas será grande, promovendo-se um passo maior de incremento para os pesos. No caso contrário, quando a solução atual estiver bem próximo da solução final, as variações nas matrizes de pesos serão bem pequenas, e, conseqüentemente, a contribuição do termo *momentum* também será reduzida (SILVA; SPATTI; FLAUZINO, 2010).

A cada iteração do processo de treinamento ocorre a propagação e a retropropagação, e o cálculo do erro quadrático de cada amostra em relação a sua saída. Na sequência obtém-se o erro quadrático médio em relação a todas as amostras, definido pela Equação 35.

$$E_{qm} = \frac{1}{s} \sum_{i=1}^s E \quad (35)$$

O critério de parada de treinamento da rede é estabelecido em função da diferença entre os erros quadráticos médios de duas iterações sucessivas. Neste caso, diz-se que o algoritmo de aprendizagem converge se a Equação 36 é satisfeita, sendo n a iteração, sendo ε a precisão necessária para garantir a convergência da rede.

$$|E_{qm}[n] - E_{qm}[n - 1]| \leq \varepsilon \quad (36)$$

APÊNDICE B – Resultados do classificador embarcado

Este Apêndice apresenta resultados adicionais do teste realizado com o classificador Hierarquia de Perceptrons embarcado no dispositivo vestível. A Tabela 24 apresenta a matriz de confusão média dos testes, enquanto as Tabelas 25, 26 e 27 exibem as matrizes de confusão dos resultados obtidos com os participantes S_1 , S_2 e S_3 , respectivamente.

Tabela 24 - Matriz de confusão média dos testes.

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
Atividades classificadas	Sentado	100,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Em pé	0,00%	100,00%	0,00%	1,70%	0,73%	0,00%
	Andando	0,00%	0,00%	56,38%	24,34%	4,36%	1,04%
	Subindo	0,00%	0,00%	39,20%	69,17%	25,98%	15,69%
	Descendo	0,00%	0,00%	4,41%	4,79%	68,92%	0,00%
	Correndo	0,00%	0,00%	0,00%	0,00%	0,00%	83,26%

Tabela 25 - Matriz de confusão do participante S_1 .

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
Atividades classificadas	Sentado	100,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Em pé	0,00%	100,00%	0,00%	0,00%	0,00%	0,00%
	Andando	0,00%	0,00%	95,51%	37,94%	6,19%	0,00%
	Subindo	0,00%	0,00%	0,00%	62,06%	2,48%	2,99%
	Descendo	0,00%	0,00%	4,49%	0,00%	91,33%	0,00%
	Correndo	0,00%	0,00%	0,00%	0,00%	0,00%	97,01%

Tabela 26 - Matriz de confusão do participante S₂.

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
Atividades classificadas	Sentado	100,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Em pé	0,00%	100,00%	0,00%	0,00%	0,00%	0,00%
	Andando	0,00%	0,00%	86,85%	59,42%	2,18%	0,00%
	Subindo	0,00%	0,00%	0,00%	21,41%	0,00%	0,00%
	Descendo	0,00%	0,00%	13,15%	19,17%	97,82%	0,00%
	Correndo	0,00%	0,00%	0,00%	0,00%	0,00%	100,00%

Tabela 27 - Matriz de confusão do participante S₃.

		Atividades observadas					
		Sentado	Em pé	Andando	Subindo	Descendo	Correndo
Atividades classificadas	Sentado	100,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Em pé	0,00%	100,00%	0,00%	6,80%	2,92%	0,00%
	Andando	0,00%	0,00%	43,18%	0,00%	9,06%	4,17%
	Subindo	0,00%	0,00%	56,82%	93,20%	1,46%	19,58%
	Descendo	0,00%	0,00%	0,00%	0,00%	86,55%	0,00%
	Correndo	0,00%	0,00%	0,00%	0,00%	0,00%	76,25%