

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**RECONHECIMENTO DE ATIVIDADES HUMANAS UTILIZANDO REDES
NEURAIS AUTO-ASSOCIATIVAS E DADOS DE SMARTPHONE**

ANDRÉ LUIS CARVALHO SIQUEIRA

DM 29/2016

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

2016

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ANDRÉ LUIS CARVALHO SIQUEIRA

**RECONHECIMENTO DE ATIVIDADES HUMANAS UTILIZANDO REDES
NEURAIAS AUTO-ASSOCIATIVAS E DADOS DE SMARTPHONE**

DM 29/2016

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2016

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**RECONHECIMENTO DE ATIVIDADES HUMANAS UTILIZANDO REDES
NEURAIS AUTO-ASSOCIATIVAS E DADOS DE SMARTPHONE**

ANDRÉ LUIS CARVALHO SIQUEIRA

Dissertação submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Pará para a obtenção do Grau de Mestre em Engenharia Elétrica na área de Computação Aplicada, elaborada sob a orientação da Profa. Dra. Adriana Rosa Garcez Castro.

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

2016

Dados Internacionais de Catalogação - na – Publicação (CIP) Sistema de Bibliotecas da UFPA

Siqueira, André Luís Carvalho, 1989-

Reconhecimento de atividades humanas utilizando redes neurais auto-associativas e dados de smatphone / André Luís Carvalho Siqueira.- 2016.

Orientador a: Adriana Rosa Garcez Castro

Dissertação (Mestrado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2016.

1. Redes neurais (computação) . 2. Comportamento humano - análise – processamento de dados. 2. Avaliação de comportamento – processamento de dados. I. Título.

CDD 23. ed. 006.32

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**RECONHECIMENTO DE ATIVIDADES HUMANAS UTILIZANDO REDES
NEURAIS AUTO-ASSOCIATIVAS E DADOS DE SMARTPHONE**

AUTOR: ANDRÉ LUIS CARVALHO SIQUEIRA

DISSERTAÇÃO DE MESTRADO SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA COM ÊNFASE EM INTELIGÊNCIA COMPUTACIONAL.

APROVADA EM: 16 de Dezembro de 2016

Professora. Dra. Adriana Rosa Garcez Castro

ORIENTADORA - PPGEE/UFPA

Professor Dr. Roberto Célio Limão de Oliveira

AVALIADOR INTERNO - PPGEE/UFPA

Professora Dra. Valquíria Gusmão Macedo

AVALIADORA EXTERNA AO PROGRAMA - FEE/UFPA

VISTO:

Professor Dr. Evaldo Gonçalves Pelaes

COORDENADOR DO PPGEE/ITEC/UFPA

“À minha família, sempre”

AGRADECIMENTOS

Antes de tudo agradeço a Deus pela oportunidade que me foi dada de viver e amar!

À minha mãe Gorete por ser a mulher mais corajosa e mais bondosa que eu conheço, por ter lutado pela educação e saúde dos filhos sempre com muito Amor. Ao meu pai Adeládio por ter me ensinado a pescar, pelo bom caráter e por ter conseguido o lugar mais precioso da nossa família: um pacato e sereno lugar no Cupijó. Sem meus pais jamais teria chegado até aqui! Muito obrigado, vocês são os melhores pais e meus melhores amigos.

À minha orientadora Adriana Castro pela excelente orientação, pelo apoio, pelo incentivo, pelas leituras, pela paciência e principalmente por ter confiado em mim, por ter me dado uma chance de alcançar meus sonhos.

Em memória à minha tia Fátima cujas eternas boas lembranças e filosofia de vida sempre estarão conosco. Quero agradecer também aos meus avós Nazaré e José por ensinarem-me sobre a simplicidade da vida em todos os seus níveis. A felicidade realmente está nas coisas mais simples do mundo.

Aos meus irmãos Hadriane, Andrea, Adrielly e Alessandro pela companhia, fraternidade, brigas e por todos os momentos especiais no Cupijó. Aos meus cunhados Marcelo, Neto e Max por fazerem parte da família. Aos meus sobrinhos Heitor, Heloísa e Enzo por terem chegado para alegrar. À minha tia Ana pelo apoio constante. À Lúcia, mãe do coração, pelos conselhos. Um agradecimento especial a toda minha família que sempre será o núcleo de tudo o que é bom para mim.

À minha namorada, Márcia, pelo ajuda constante, dedicação, carinho e amor.

Agradeço a Antônio e Nelly por me receberem em sua casa, pelo suporte, pelas conversas e troca de experiências.

A todos os meus amigos pelos momentos vividos dentro e fora da faculdade. À Luanna, Lua, Charllene, Douglas, Eduardo, Juliana, Danilo, Juan, Lauren, Thiana, Iana e Arthur obrigado pela força.

Aos meus professores, por todo o aprendizado, sobretudo pelo apoio durante o curso. Finalmente agradeço à UFPA, CNPq, CAPES e ao PPGEE pelo apoio durante todo o mestrado.

“A verdadeira sabedoria é um dom de Deus”

Jó 28:1-28

SUMÁRIO

LISTA DE FIGURAS	XII
LISTA DE TABELAS	XIII
LISTA DE ABREVIATURAS E SIGLAS	XIV
RESUMO	XV
ABSTRACT	XVI
1 INTRODUÇÃO	1
1.1 DEFINIÇÃO DO PROBLEMA E MOTIVAÇÃO.....	1
1.2 OBJETIVO GERAL E OBJETIVOS ESPECÍFICOS.....	2
1.3 ESTRUTURA DO TRABALHO.....	2
2 RECONHECIMENTO DE ATIVIDADES HUMANAS	4
2.1 CONSIDERAÇÕES INICIAIS.....	4
2.2 RECONHECIMENTO DE ATIVIDADES HUMANAS.....	5
2.3 ETAPAS PARA RECONHECIMENTO DE ATIVIDADES HUMANAS.....	6
2.4 CAPTURA E PRÉ-PROCESSAMENTO DE DADOS.....	8
2.4.1 SENSORES.....	9
2.4.2 ATIVIDADES HUMANAS.....	12
2.4.3 PRÉ-PROCESSAMENTO DE DADOS.....	15
2.5 EXTRAÇÃO DE CARACTERÍSTICAS.....	16
2.6 CLASSIFICAÇÃO DE ATIVIDADES.....	18
2.7 AVALIAÇÃO DO CLASSIFICADOR.....	20
3 REDES NEURAS ARTIFICIAIS AUTO-ASSOCIATIVAS	23
3.1 CONSIDERAÇÕES INICIAIS.....	23
3.2 REDES NEURAS ARTIFICIAIS.....	23
3.2.1 PERCEPTRON MULTICAMADAS.....	26
3.3 REDES NEURAS ARTIFICIAIS AUTO-ASSOCIATIVAS.....	27
3.4 ESTADO DA ARTE DE REDES NEURAS ARTIFICIAIS APLICADAS A RAH.....	28
4 REDES NEURAS AUTO-ASSOCIATIVAS PARA RAH	31
4.1 CONSIDERAÇÕES INICIAIS.....	31
4.2 BASE DE DADOS.....	32
4.3 SISTEMA PARA RECONHECIMENTO DE ATIVIDADES HUMANAS.....	36
4.3.1 CENÁRIO 1.....	39

4.3.2	CENÁRIO 2	41
4.4	RESULTADOS E DISCUSSÃO.....	44
5	CONCLUSÃO	45
6	REFERÊNCIAS BIBLIOGRÁFICAS	47

LISTA DE FIGURAS

Figura 2.1 Etapas de Sistemas de Reconhecimento de Atividades Humanas	8
Figura 2.2 Cenário Híbrido com utilização de sensores vestíveis	9
Figura 2.3 Representação de <i>smartphone</i> com acelerômetro e giroscópio de 3 eixos.	11
Figura 2.4 Ilustração de sinais obtidos por acelerômetro e giroscópio de atividades básicas ..	14
Figura 2.5 Exemplificação de segmentação de 2.56s ou 128 amostras/janela com <i>overlap</i> de 50%.....	16
Figura 2.6 Matriz de confusão genérica.	21
Figura 3.1 Estrutura básica de um neurônio artificial	23
Figura 3.2 Funções de ativação que podem ser utilizadas por um neurônio artificial	24
Figura 3.3 Arquitetura de uma rede MLP de duas camadas escondidas.	26
Figura 3.4 Ilustração de uma rede neural auto-associativa com camada intermediária com menos neurônios do que as camadas de entrada e saída.....	27
Figura 4.1 Janela com 128 amostras da atividade Caminhar	33
Figura 4.2 Ilustração do sistema de RAH baseado em 6 redes auto-associativas	38
Figura 4.3 Ilustração genérica das RNAAs treinadas para cada atividade no cenário 1	39
Figura 4.4 Ilustração genérica das RNAAs treinadas para cada atividade no cenário 2	42

LISTA DE TABELAS

Tabela 2.1 Classificação de atividades por duração, complexidade e tipos.	13
Tabela 2.2 Grupos de características e métodos pelos quais as mesmas são extraídas.	17
Tabela 2.3 Tipos de algoritmos de AM mais utilizados em RAH.....	19
Tabela 4.1 Lista de Funções para extração das variáveis.	34
Tabela 4.2 Matriz de confusão para a base de testes cenário 1	40
Tabela 4.3 Matriz de confusão para a base de testes no cenário 2	43

LISTA DE ABREVIATURAS E SIGLAS

ADL	<i>Activities of Daily Living</i>
AmI	Ambientes Inteligentes
AVA	Ambiente de Vida Assistida
CNN	<i>Convolutional Neural Network</i>
CAE	<i>Continuous Autoencoders</i>
CI	Casa Inteligente
DCNN	<i>Deep Convolutional Neural Networks</i>
FFT	<i>Fast Fourier Transform</i>
ICF	<i>International Classification of Functioning, Disability and Health</i>
KDD	<i>Knowledge -Discovery in Databases</i>
k-NN	<i>k- Nearest Neighbors</i>
LDA	<i>Linear Discriminant Analysis</i>
MEMS	<i>Microelectromechanical Systems</i>
MLP	<i>Multi-layer perceptron</i>
NLPCA	<i>Nonlinear Principal Component Analysis</i>
OMS	Organização Mundial de Saúde
PCA	<i>Principal Component Analysis</i>
RAH	Reconhecimento de Atividades Humanas
RNA	Redes Neurais Artificiais
RNAA	Rede Neural Auto-Associativa
SVM	<i>Support Vector Machine</i>

RESUMO

O Reconhecimento de Atividades Humanas (RAH) é uma área de pesquisa importante e desafiadora, com muitas aplicações na área de ambientes inteligentes, saúde e segurança domiciliar. RAH pode ser visto como um processo pelo qual o comportamento de uma pessoa é monitorado e analisado para inferir quais as atividades que estão sendo realizadas em determinado período de tempo.

Este trabalho apresenta a criação de dois sistemas para RAH baseado em Redes Neurais Auto-associativas desenvolvidos a partir de um banco de dados público composto por sinais de 6 atividades básicas. Os sinais foram adquiridos a partir de um acelerômetro e giroscópio de um Smartphone e tanto as características extraídas dos sinais no domínio do tempo quanto sinais brutos da aceleração do corpo foram utilizadas para o desenvolvimento dos sistemas de RAH propostos. Os resultados obtidos mostram a eficácia do sistema e a aplicabilidade das Redes Neurais Auto-associativas para o problema de RAH.

PALAVRAS-CHAVES: RAH, redes neurais auto-associativas, acelerômetro, giroscópio

ABSTRACT

Human Activity Recognition (HAR) is an important challenging research area with many applications in intelligence ambient, healthcare and homeland security systems. HAR is the process whereby a person is monitored through sensors and analyzed to infer the undergoing activities during a period of time.

This work presents the development of two systems for the HAR using auto associative neural networks. The activity recognition systems are based on public dataset that has signal from three static postures (standing, sitting, lying) and three dynamic activities (walking, walking downstairs and walking upstairs).The dataset was captured by using accelerometer and gyroscopic sensor of a Smartphone. The features extracted from the time and the acceleration due to body motion were used to the development of the proposed systems. Our experimental results illustrates the effectiveness of the proposed system.

KEYWORDS: HAR, auto associative neural networks, accelerometer, gyroscope

1 INTRODUÇÃO

1.1 DEFINIÇÃO DO PROBLEMA E MOTIVAÇÃO

O conceito de ambientes inteligentes vem ganhando espaço no cenário tecnológico atual e trata-se de um termo utilizado para definir ambientes que integram tecnologia e serviços, visando aumento na qualidade de vida das pessoas. São ambientes onde as interações dos indivíduos que nele frequentam são ditas como parte dos próprios ambientes em si.

Diante desse contexto, o Reconhecimento de Atividades Humanas (RAH) pode contribuir para o desenvolvimento de sistemas para ambientes inteligentes, uma vez que a classificação adequada das atividades das pessoas dentro desses ambientes facilitaria a interação entre o ambiente e o indivíduo.

Existem diversos métodos computacionais pelos quais os dados capturados por sensores dentro desses ambientes inteligentes podem ser analisados e transformados em ferramentas de reconhecimento de atividades humanas. Métodos tais como *Árvore de Decisão* (BAYAT; POMPLUN; TRAN, 2014; FAN; WANG; WANG, 2013), *Naive Bayes* (ORTIZ, 2015), *Support Vector Machine* (SVM) (ANGUITA et al., 2013; ORTIZ, 2015) e *Redes Neurais Artificiais* (AGUIAR et al., 2014; KWAPISZ; WEISS; MOORE, 2011; ONIGA; SUTO, 2014; ZHANG et al., 2013) vêm sendo utilizados com sucesso.

Apesar dos bons resultados das metodologias já apresentadas na literatura na área de RAH, muitas pesquisas vêm sendo realizadas visando encontrar técnicas mais avançadas, uma vez que, dentro do contexto de ambientes inteligentes implementados em sistemas de classificação em tempo real, a resposta deve ser rápida e confiável o suficiente para a tomada de decisão.

Pela análise dos trabalhos correlatos, percebe-se a inexistência de sistemas de RAH baseado em *Redes Neurais Auto-associativas* (RNAA). Uma rede RNAA é um caso especial da *Perceptron* de múltiplas camadas, onde o número de entradas da rede é igual ao número de saídas, sendo a rede treinada para realizar um mapeamento do vetor de entrada no vetor de saída. A rede é treinada para reproduzir em sua saída os dados apresentados em sua entrada sendo que a camada intermediária funciona como codificador que permite que a rede

armazene somente conhecimento relacionado às principais características do conjunto de dados de entrada.

Dada as características das RNAAs, é possível que as mesmas apresentem grande potencial na área de RAH, principalmente pela sua capacidade de mapeamento de identidade na realização de tarefas de classificação, capacidade esta já exploradas em outras áreas como Sistemas de Potência (MIRANDA; CASTRO; LIMA, 2011) e Médica (CHAKROBORTY, 2013).

1.2 OBJETIVO GERAL E OBJETIVOS ESPECÍFICOS

Diante da importância do reconhecimento de atividades humanas, este trabalho tem como objetivo principal o desenvolvimento de sistemas de RAH baseados em Redes Neurais Auto-associativas e verificação da aplicabilidade e eficiência da mesma para o problema em questão.

Como objetivos específicos têm-se:

1. Criação de dois sistemas, discutidos em dois cenários diferentes, utilizando sinais obtidos a partir de acelerômetro e giroscópio de um *smartphone*. No cenário 1 serão utilizadas características extraídas do domínio do tempo dos sinais. No cenário 2 serão utilizados os sinais brutos da aceleração do corpo, onde será testada a viabilidade da utilização dos mesmos para RAH. Em ambos os cenários os sinais utilizados foram obtidos em um banco de dados público criado por Anguita *et al* (2013).

2. Desenvolvimento de ambos os sistemas com taxa de acerto próxima ou superior aos já encontrados na literatura.

1.3 ESTRUTURA DO TRABALHO

Esta dissertação está organizada em cinco capítulos. O Capítulo 1 apresenta uma introdução à problemática a ser investigada e a motivação do trabalho. No Capítulo 2 são expostos conceitos correlacionados com o reconhecimento de atividades humanas e as etapas pertinentes ao processo de criação de sistemas de reconhecimento de atividades. Em seguida,

no capítulo 3, apresenta-se a fundamentação teórica básica sobre redes neurais, relatando sobre *Perceptron* de múltiplas camadas e ainda sobre as Redes Neurais Auto-associativas e os trabalhos correlatos relacionados às mesmas. O Capítulo 4 apresenta a metodologia proposta da dissertação, os resultados e a discussão sobre o que foi alcançado. O Capítulo 5 apresenta algumas considerações finais acerca da pesquisa, assim como trabalhos futuros.

2 RECONHECIMENTO DE ATIVIDADES HUMANAS

2.1 CONSIDERAÇÕES INICIAIS

A integração de novas tecnologias no dia a dia das pessoas tem crescido rapidamente e consequentemente a interação entre máquinas e humanos também. Diante desse acentuado crescimento novos paradigmas surgem e com eles novos desafios.

Para Gandetto *et al* (2003) e Ortiz (2015) o conceito de Ambientes Inteligentes (AmI) é um paradigma que explora ambientes inteligentes e adaptativos nos quais as ações das pessoas que nele residem fazem parte dos próprios ambientes em si. A aplicação de AmI pode ocorrer em vários setores, inclusive no setor de Casa Inteligente (do inglês *Smart Home*) e Ambiente de Vida Assistida (do inglês, *Ambient Assisted Living*).

O termo Casa Inteligente (CI) designa uma casa que integra tecnologia e serviços visando o aumento na eficiência energética e qualidade de vida das pessoas. Existem diversas vantagens que uma CI pode proporcionar, como: monitoração dos filhos enquanto se trabalha, execução do trabalho doméstico diário de forma mais prazerosa e em menos tempo, proteção da residência e utilização de fontes de energia de modo mais inteligente e racional (BOLZANI, 2004).

Segundo a Organização Mundial de Saúde (OMS) a expectativa de vida das pessoas tem crescido nos últimos anos e cerca de 15% da população mundial tem algum tipo de incapacidade (WORLD HEALTH ORGANIZATION *et al.*, 2016). A *International Classification of Functioning, Disability and Health* (ICF) define como incapacidade um termo genérico para deficiências, limitações de atividades e restrições de movimento em geral. Assim sendo, o Ambiente de Vida Assistida (AVA) torna-se um importante meio de se buscar soluções, por exemplo, que melhorem a autonomia e a qualidade de vida de pessoas idosas ou com algum tipo de incapacidade.

Diante desse contexto, o reconhecimento de atividades humanas pode vir a contribuir para o desenvolvimento de sistemas para Ambientes Inteligentes tanto no setor de CI quanto no setor de AVA. O RAH é uma área de pesquisa importante e desafiadora, com muitas aplicações na área da saúde, ambientes inteligentes e segurança domiciliar (BAYAT; POMPLUN; TRAN, 2014; CHEN *et al.*, 2011) e vem sendo estudada há anos, com

pesquisadores da área propondo diferentes soluções para o problema (RASEKH; CHEN; LU, 2011).

Como relatado na seção 1, a proposta deste trabalho visa a criação de um sistema para RAH. Os tópicos a seguir apresentam então um embasamento teórico sobre RAH necessário para o bom entendimento da metodologia e tarefas propostas nesta dissertação.

2.2 RECONHECIMENTO DE ATIVIDADES HUMANAS

O Reconhecimento de atividades humanas é um processo pelo qual o comportamento de uma pessoa é monitorado e analisado para inferir quais as atividades que estão sendo realizadas (CHEN et al., 2011).

O RAH é um campo de estudo decisivo para criação de AmI e pode ser considerado um dos pontos mais relevantes para a implementação real desses ambientes. Além da aplicação em AmI, o RAH pode também ser aplicado em diversos setores como os da área de saúde, de entretenimento e esportes e de segurança domiciliar (BULLING; BLANKE; SCHIELE, 2014; CHEN et al., 2012; LARA; LABRADOR, 2013; LE; NGUYEN, 2015).

No contexto do setor de saúde, o RAH é importante para a criação de ambientes de monitoramento de pessoas idosas (ABBATE; AVVENUTI; CORSINI, 2010; AGUIAR et al., 2014; ÁLVAREZ DE LA CONCEPCIÓN et al., 2016; VAVOULAS et al., 2013), com algum tipo de incapacidade ou ainda em reabilitação (KANGAS, 2011; LUŠTREK; KALUŽA, 2008; ONIGA; SUTO, 2014; VEGA, 2016).

Sistemas de RAH podem dar suporte para a detecção de Atividades da Vida Diária (ADL, do inglês *Activities of Daily Living*) primeiramente definido por Katz *et al.* (1970), tendo surgido como uma compilação das principais atividades realizadas no cotidiano das pessoas e utilizada como base para criação de ferramentas para a detecção de problemas na realização independente de atividades.

No setor de entretenimento o RAH vem sendo usado em plataformas de jogos para melhorar a experiência dos usuários ou ainda, por exemplo, para acompanhar pacientes em tratamento através do Kinect da Microsoft (TAKAČ et al., 2013). Em relação a aplicações de RAH para esportes, existem trabalhos tais como os de Chambers (2002), Ermes *et al.* (2008), Long *et al.* (2009) e Sefen *et al.* (2016) voltados para o reconhecimento de atividades físicas

como, por exemplo, andar de bicicleta, correr, jogar futebol, tênis de mesa e sistemas para gerar alertas sobre gasto energético e realizar acompanhamento de rendimento por parte do atleta. Nesse sentido existem produtos sendo fabricados como tênis, roupas e acessórios inteligentes que possuem sensores de reconhecimento de atividade afim de se melhorar a performance e rendimento do usuário (AVCI et al., 2010; NIKE, 2016).

Para Ustev *et al.* (2013), o RAH pode ser definido como um processo de interpretação de dados brutos coletados por sensores para classificar um conjunto de atividades. Já para Labrador e Yejas (2013) um problema de RAH é definido como sendo um conjunto de atividades $S = \{S_0, \dots, S_{k-1}\}$ ao longo de k séries temporais, onde cada atividade é singular e todas são definidas dentro de um intervalo de tempo $I = [t_0, t_w]$, cujo objetivo é procurar uma partição da série temporal $\{I_0, \dots, I_{r-1}\}$ de I , relacionada com a atividade S , e estabelecer uma classe que represente determinada atividade realizada durante cada intervalo de tempo I_j . Isso implica que a série temporal é consecutiva, não vazia e não se sobrepõe de modo que $\bigcup_{j=0}^{r-1} I_j = I$.

Para que um conjunto S de atividades seja reconhecido, primeiramente é necessário que estas atividades passem por uma série de etapas envolvidas no processo de criação de um sistema de RAH.

2.3 ETAPAS PARA RECONHECIMENTO DE ATIVIDADES HUMANAS

Segundo Chen *et al.* (2011), o processo para RAH compreende diversas etapas tais como modelagem das atividades a serem reconhecidas, monitoramento e captura de dados de sensores, processamento de dados e finalmente reconhecimento de padrões.

Em (BAYAT; POMPLUN; TRAN, 2014; LABRADOR; YEJAS, 2013) os autores definem que um sistema para RAH deve passar pelos processos de captura de dados das atividades, análise dos dados capturados, construção de classificador de atividade e tomada de decisão.

Em Ustev *et al.* (2013) é enfatizado que os estágios para RAH são a captura de dados através de sensores, o processamento e segmentação dos dados, a extração de características e a classificação das atividades.

Para Safonov *et al.* (2015) as etapas para criação de sistemas de RAH consistem em coleta de dados e atribuição de classes, representação, criação de modelo classificador, avaliação e otimização.

Ortiz (2015) cita 4 estágios pelo qual um sistema para RAH deve passar: sensoriamento, análise dos dados dos sensores, criação do modelo classificador e tomada de decisão.

Relata-se em Bulling *et al* (2014) que os principais passos são sensoriamento, pré-processamento dos dados, extração de características, treinamento e classificação.

Ressalta-se que as etapas para a criação de um sistema de RAH é uma especialização do *Knowledge Discovery in Databases* (KDD) o qual é um processo iterativo, interativo e não trivial de identificação de novos padrões válidos, úteis e compreensíveis, tendo como vantagem a extração de conhecimento de dados sem a necessidade de conhecimento prévio ou hipóteses (FAYYAD *et al.*, 1996) .

Baseado na literatura pode-se perceber então que as principais etapas para a criação de sistemas RAH são: a captura e pré-processamento dos dados, a extração de características, a construção do classificador e a avaliação do classificador. A Figura 2.1 ilustra essas etapas e nas próximas secções cada uma delas será detalhada.

De forma geral, na etapa de captura e pré-processamento de dados ocorre a escolha dos sensores e dispositivos a serem utilizados na coleta ou a escolha da fonte de dados que dispõe de um conjunto de atividades. Nessa fase também ocorre o tratamento inicial dos dados, a aplicação de filtros, a retirada ou a redução de ruídos inerentes à captura, por exemplo.

Na etapa de extração de características o objetivo é obter as características que melhor representam o conjunto de dados em estudo. Após esse processo, as características extraídas servem como entrada para um algoritmo de Aprendizado de Máquina (AM) afim de que um modelo classificador seja construído. Em seguida, as atividades preditas são submetidas à etapa de avaliação para que o modelo de classificação seja validado de acordo com medidas de avaliação de desempenho.

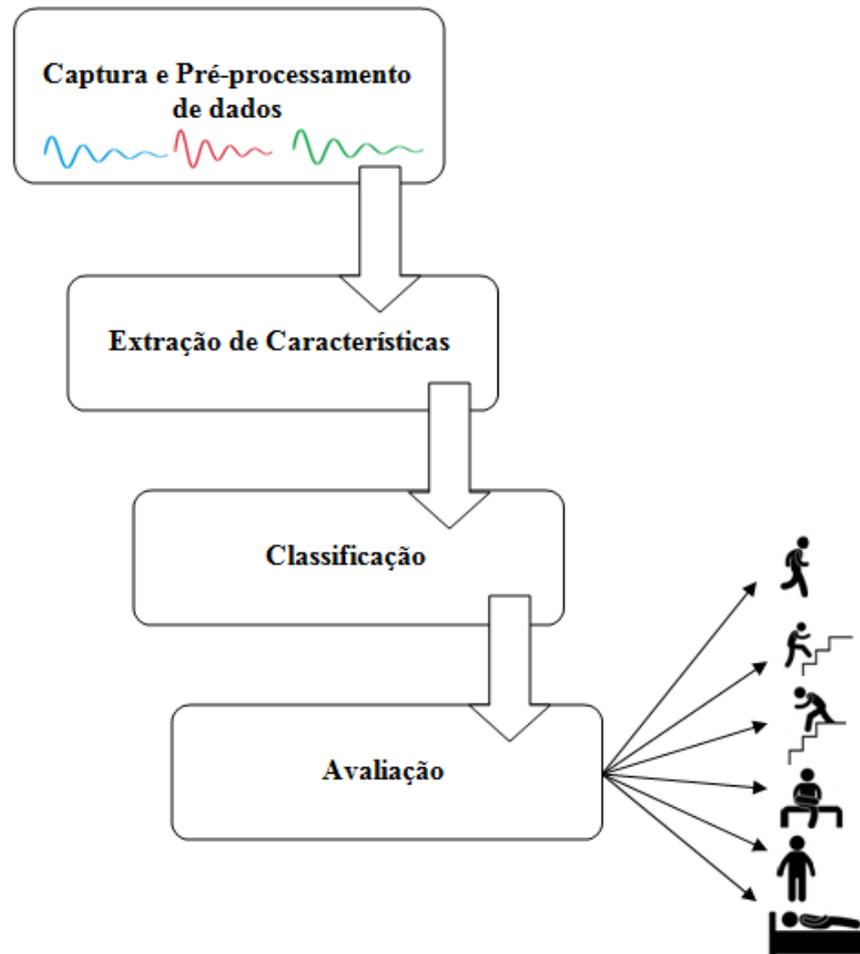


Figura 2.1 Etapas de Sistemas de Reconhecimento de Atividades Humanas

2.4 CAPTURA E PRÉ-PROCESSAMENTO DE DADOS

Monitorar a atividade de uma pessoa em um ambiente é uma tarefa crucial para o RAH. Esse monitoramento é responsável pela captura das informações mais relevantes para a criação de sistemas que predizem atividades realizadas pelas pessoas (CHEN et al., 2011). Além do mais, tanto AmI quanto AVA precisam de informações dos usuários e do ambiente com o qual estes interagem para que sistemas inteligentes sejam criados (LARA; LABRADOR, 2013; ORTIZ, 2015).

O reconhecimento de atividades humanas é realizado a partir de dados provenientes de sensores e os dados são capturados durante um período de monitoração contínua das atividades de um indivíduo, sendo que a coleta pode ser feita de diferentes maneiras (SILVA G., 2013).

2.4.1 SENSORES

A escolha adequada dos sensores para esta coleta de dados é um dos primeiros elementos a se levar em consideração para a construção de sistemas de RAH (ORTIZ, 2015; SILVA C., 2013).

Sensores externos normalmente são sensores dispostos no ambiente no qual as atividades de uma pessoa ou grupo de pessoas serão monitoradas. Nesse cenário podem ser utilizados como, por exemplo, sensores de áudio, de vídeo, de presença e de temperatura para se obter informações contextuais do ambiente (FU, 2016; GUO et al., 2016; LABRADOR; YEJAS, 2013; ORTIZ, 2015; SILVA G., 2013).

Sensores vestíveis são sensores de tamanho reduzido que permitem o seu acoplamento ao corpo ou à vestimenta do usuário de modo que funcionam sem que o usuário precise manipulá-los todo tempo (BAYAR; YAYAN; YAZICI, 2016; RAVI et al., 2005; SILVA G., 2013). Os sensores vestíveis são eficientes e relativamente menos custosos para a aquisição de dados de atividades humanas, principalmente as atividades físicas (CHEN et al., 2011; UDDIN et al., 2015).

A Figura 2.2 exibe um cenário híbrido onde tanto sensores externos quanto sensores vestíveis são utilizados para o monitoramento de atividades humanas.

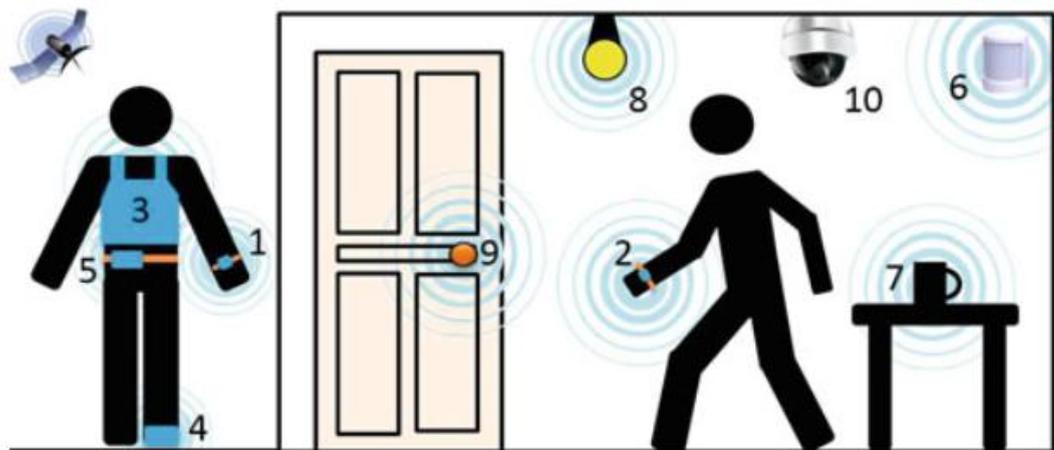


Figura 2.2 Cenário Híbrido com utilização de sensores vestíveis

1- Relógio com GPS, 2- Sensor de movimento, 3- sensor de sinais vitais, 4- Pedômetro, 5- *Smartphone* e sensores externos, 6- Sensor de presença, 7- Sensor de proximidade, 8- Sensor de luminosidade, 9- Sensor de abertura de porta, 10- Câmera de vídeo). Fonte: Adaptado de Ortiz (2015)

Na literatura existem diversos trabalhos relatando o uso de sensores como acelerômetros triaxial (AGUIAR et al., 2014; ANGUITA et al., 2013; BAYAT; POMPLUN; TRAN, 2014; FAN; WANG; WANG, 2013; KWAPISZ; WEISS; MOORE, 2011; ONIGA; SUTO, 2014; SILVA G., 2013; ZHANG et al., 2013, 2006), giroscópios (FU, 2016; LABRADOR; YEJAS, 2013; LI et al., 2008; NOURY et al., 2007; ORTIZ, 2015; ORTIZ; ONETO; SAM, 2016; SHOAIIB et al., 2014), sensores cardíacos (ONIGA; SUTO, 2014), sensores de sinais vitais (LABRADOR; YEJAS, 2013) e imagens (CHAMBERS, 2002; FU, 2016).

Percebe-se uma grande utilização de acelerômetros e giroscópios nos mais diversos trabalhos e a razão por trás dessa ampla utilização pela comunidade científica se deve à miniaturização dos mesmos, pelo baixo consumo de energia e pela capacidade de fornecerem dados diretamente relacionados ao movimento (AGUIAR et al., 2014; CASALE; PUJOL; RADEVA, 2012; LABRADOR; YEJAS, 2013; SILVA G., 2013).

Os *smartphones* são os dispositivos portáteis com os quais as pessoas mais interagem enquanto estão realizando suas atividades diárias (GHOSH; RICCARDI, 2014; ORTIZ, 2015; REISS; HENDEBY; STRICKER, 2013). Segundo a União Internacional de Telecomunicações (ITU, 2016) cerca de 95% da população mundial vive sobre uma área com cobertura dos *smartphones*. Apesar desse fato não representar a mesma proporção quanto ao acesso à internet e qualidade de conexão, isto mostra o poder de alcance e popularidade desses dispositivos no mundo inteiro. Dado o crescimento da popularidade e do poder computacional dos *smartphones*, estes vêm se tornando candidatos ideais para captura de dados de forma não-intrusiva (GUO et al., 2016; RASEKH; CHEN; LU, 2011).

Além disso, os *smartphones* vêm incorporando diversos sensores tais como GPS, câmeras, sensores de luz, de direção, microfones, acelerômetros e giroscópios (KWAPISZ; WEISS; MOORE, 2011; LANE; MILUZZO; LU, 2010). Segundo Lane *et al* (2010) os acelerômetros e giroscópios foram incluídos aos celulares nos últimos anos e isso possibilitou o uso desses aparelhos na captura de dados de atividades humanas.

2.4.1.1 ACELERÔMETRO

Através desses sensores é possível medir não só acelerações (dinâmicas), como também inclinação, rotação, vibração, colisão e gravidade (acelerações estáticas), constituindo assim um sensor de elevada utilidade para projetos na área da eletrônica e robótica (FIGUEIREDO et al., 2007).

A aceleração e direção podem ser obtidos através de sensores de um, dois ou três eixos, utilizando acelerômetros uni, bi ou triaxiais, respectivamente, sendo que os acelerômetros triaxiais são os mais comuns nos dispositivos eletrônicos comerciais (ORTIZ, 2015; PATSKO, 2006).

A Figura 2.3 ilustra um *smartphone* com acelerômetro de 3 eixos representados pelas setas. Um acelerômetro triaxial é um sensor que retorna uma estimativa real da aceleração (dada em m/s^2) ao longo dos eixos x , y e z do qual a velocidade e deslocamento também podem ser estimados, sendo muito adequados ao RAH (RAVI et al., 2005).

Existem diversos tipos de acelerômetros, mas os que compõe atualmente a maioria dos dispositivos, incluindo celulares, são construídos com a tecnologia dos Sistemas Microeletromecânicos (do inglês, *Microelectromechanical Systems* MEMS) o qual permitiu a fabricação desses sensores a um baixo custo, com aumento em sua sensibilidade e diminuição em seu tamanho.

Os acelerômetros possuem uma largura de banda que indica a frequência com a qual o componente medirá a aceleração e atualizará o sinal de saída. Em Maurer *et al.* (2006) foram estudadas as mudanças dessa faixa entre 10Hz e 100Hz e foi percebido que não há um ganho significativo na taxa de acerto do sistema com bandas acima de 20Hz para determinadas atividades.

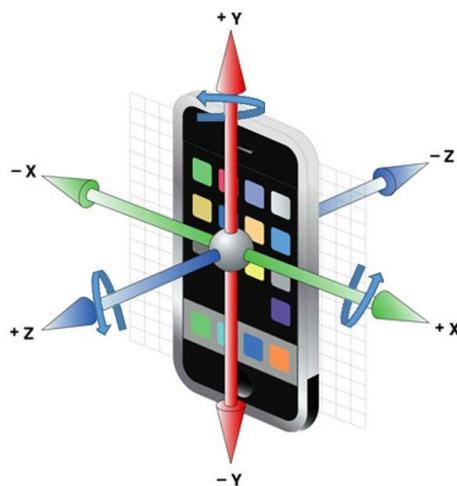


Figura 2.3 Representação de *smartphone* com acelerômetro e giroscópio de 3 eixos.

Foi estudado também em Lara e Labrador (2013) e Maurer *et al.* (2006) outro ponto importante desses sensores que diz respeito a amplitude do sinal que geralmente varia de $\pm 2g$

até $\pm 6g$ (essa faixa de amplitude mostrou-se suficiente para a criação de sistemas de RAH), onde $1g = 9.81 m/s^2$ que representa a aceleração da gravidade. Aliás, o efeito da gravidade, segundo Ortiz (2015), pode influenciar negativamente a detecção do movimento do corpo, sendo necessária a aplicação de algum filtro para a eliminação desse efeito.

2.4.1.2 GIROSCÓPIO

Um giroscópio é um sensor que mede a orientação no espaço de determinado objeto ou corpo (WOODMAN, 2009). Em outras palavras, um giroscópio é um dispositivo que permite medir quão rápido o objeto gira em relação a um sistema de referência inercial, o que é conhecido como velocidade angular (FORHAN, 2010). Eles podem estimar com certa precisão a velocidade angular (magnitude e direção) e por isso podem ser utilizados para o reconhecimento de atividades humanas (ORTIZ, 2015).

Os giroscópios são bastante utilizados em sistemas de navegação e para aumento de estabilidade de aeronaves, por exemplo, e ultimamente vêm sendo acoplados aos *smartphones*. Assim como os acelerômetros é possível que sua medida seja feita em relação a um, dois ou três eixos e também podem ser produzidos a partir da tecnologia MEMS. A Figura 2.3 ilustra um *smartphone* também com giroscópio de 3 eixos representados pelas setas em rotação.

2.4.2 ATIVIDADES HUMANAS

Além da escolha dos sensores, outro fator importante no que concerne aos sistemas de RAH está relacionado à escolha das atividades a serem reconhecidas, as quais podem influenciar o modo como o sistema é projetado e implementado (AGGARWAL; RYOO, 2011; CHEN et al., 2011; LABRADOR; YEJAS, 2013; ORTIZ, 2015; SHOAIIB et al., 2015; SILVA G., 2013).

De forma geral as atividades podem ser classificadas de acordo com sua duração e complexidade (ORTIZ, 2015), ou ainda, de acordo com o seu tipo (AGGARWAL; RYOO, 2011; LARA; LABRADOR, 2013).

Baseado na literatura, a Tabela 2.1 apresenta atividades organizadas de acordo com sua duração, complexidade e tipos mais comuns de atividades em sistemas de RAH. As atividades curtas se caracterizam por serem eventos de pequena duração e abrangem gestos e transições entre movimentos. As atividades básicas se caracterizam por serem um pouco mais

demoradas que os eventos curtos, com movimentos repetidos e ações cíclicas. Já as atividades complexas são atividades que requerem união entre um conjunto de atividades básicas e rápidas, podendo depender de mais usuários (LABRADOR; YEJAS, 2013; ORTIZ, 2015).

Tabela 2.1 Classificação de atividades por duração, complexidade e tipos.

Duração/ Complexidade	Tipos de Atividade	Descrição	Exemplos de Atividades
Eventos curtos	Gestos	Movimentos básicos de uma parte específica do corpo da pessoa.	Levantar a mão, abaixar uma perna, balançar a cabeça, sorrir.
Atividades básicas	Estáticas	Movimentos temporários de uma pessoa que podem ser compostos de múltiplos gestos.	Caminhar, correr, pedalar, sentar, ler, ficar de pé, subir e descer escadas.
	Dinâmicas		
Atividades Complexas	Interações	Movimentos que envolvem duas ou mais pessoas e/ou objetos.	Cumprimentar com as mãos, passar um livro para outra pessoa, dança, marchas e reuniões em grupo.
	Atividades em grupo	Compostos de movimentos de múltiplas pessoas interagindo ou não com objetos.	

O foco dos sistemas de RAH utilizando acelerômetros e giroscópios concentra-se em reconhecer atividades básicas devido à limitação de número e localização dos sensores a serem acoplados no indivíduo (SILVA G., 2013). A Figura 2.4 ilustra as atividades básicas exemplificadas na Tabela 2.1 como subir escadas, descer escadas e ficar de pé, exibindo os sinais obtidos durante aproximadamente 2.56 segundos por acelerômetro e giroscópio.

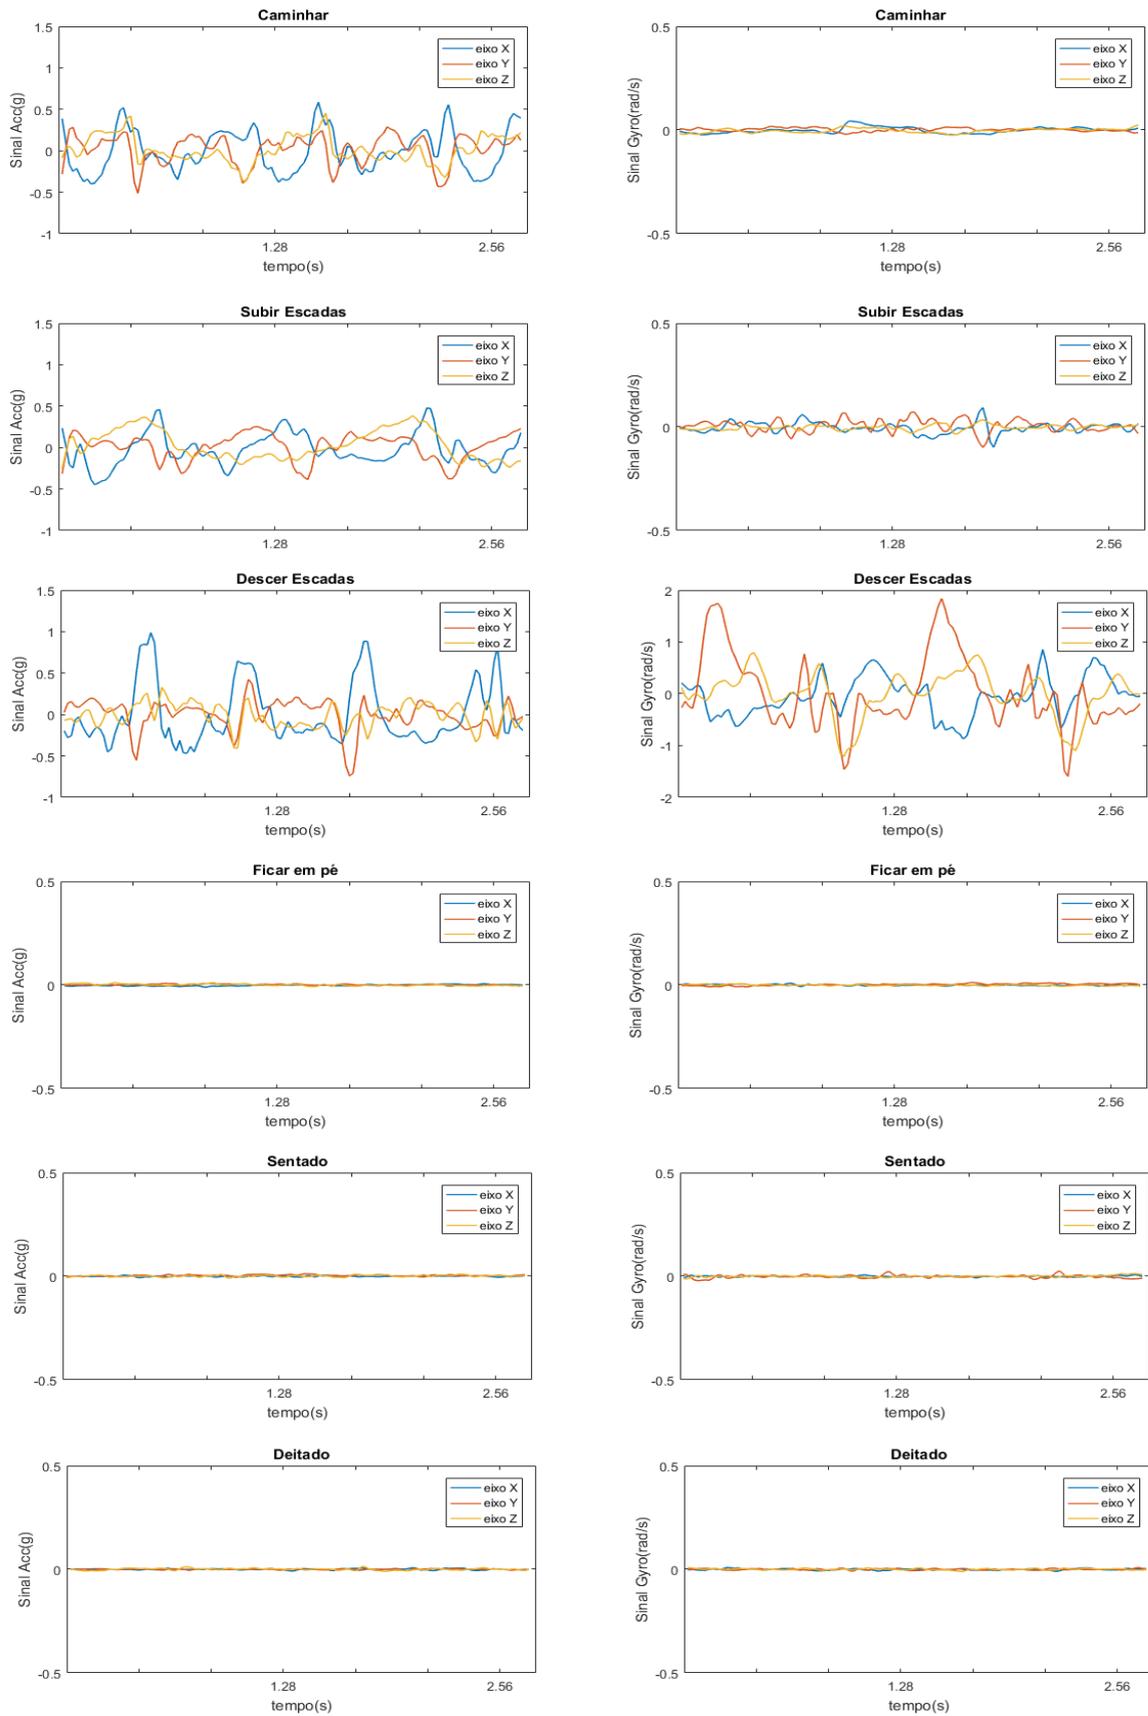


Figura 2.4 Ilustração de sinais obtidos por acelerômetro e giroscópio de atividades básicas

2.4.3 PRÉ-PROCESSAMENTO DE DADOS

Os dados coletados geralmente carregam uma série de ruídos inerentes ao processo de captura. Além de ruídos também é possível que os dados brutos contenham algum tipo de erro devido ao mau funcionamento e calibração dos sensores, devido ao erro no procedimento das atividades escolhidas ou ainda interferência eletromagnética (BULLING; BLANKE; SCHIELE, 2014; CHAUDHARY et al., 2016; GUIRY; VAN DE VEN; NELSON, 2012; SAFONOV et al., 2015).

Dessa forma, os dados brutos precisam passar por um pré-processamento a fim de se remover erros e ruídos de modo a preparar os dados para a etapa de extração de características. Geralmente o pré-processamento inclui etapas de: Remoção de dados inesperados, Interpolação, Filtro de ruídos e Normalização e sincronização dos dados capturados (UDDIN et al., 2015).

De acordo com Uddin *et al* (2015), uma das técnicas para a remoção de dados inesperados se baseia em métodos que utilizam limiares e para a interpolação, tratamentos de dados ausentes, normalmente usa-se técnicas estatísticas.

Podem-se usar diversos tipos de filtros para a eliminação de ruídos como os passa-baixa, passa-alta, Gaussianos e Laplacianos. Para RAH normalmente são utilizados filtros passa-baixa e passa-alta (UDDIN et al., 2015). Em alguns casos é necessário a aplicação de filtros para a remoção dos efeitos da aceleração gravidade nos dados a fim de se estabelecer uma distinção entre a aceleração provocada pela movimentação do corpo da pessoa com o da gravidade (AVCI et al., 2010; ORTIZ, 2015).

Após o tratamento inicial dos dados para remoção de ruídos e erros em geral, os mesmos precisam ser segmentados. A segmentação de sinais contínuos de sensores é uma tarefa difícil, pois a realização de atividades humanas é separada por pausas e o limite entre essas pausas não são bem definidos (BULLING; BLANKE; SCHIELE, 2014).

A forma mais comum de segmentação é através de janelamento, no qual os dados das atividades são divididos em janelas de mesmo tamanho, sem que haja pausas (SILVA C., 2013). Essa técnica pode fazer com que o ciclo de uma atividade não esteja dentro de um segmento, por esse motivo é crucial uma escolha adequada do número de amostras dos dados que constituirão uma janela. Sendo assim, o uso de uma janela suficientemente grande é indicada para conter o ciclo da atividade inteira (BAO; INTILLE, 2004), apesar disso representar um maior tempo de processamento (BULLING; BLANKE; SCHIELE, 2014) e

gerar o problema de mais de um ciclo de atividade dentro da mesma janela (LABRADOR; YEJAS, 2013).

A Figura 2.5, adaptada de Silva G. (2013), ilustra a segmentação dos dados do eixo X de um acelerômetro realizada por janelamento de 2.56s com *overlap* de 50%, resultando em 6 janelas de 128 amostras/janela.

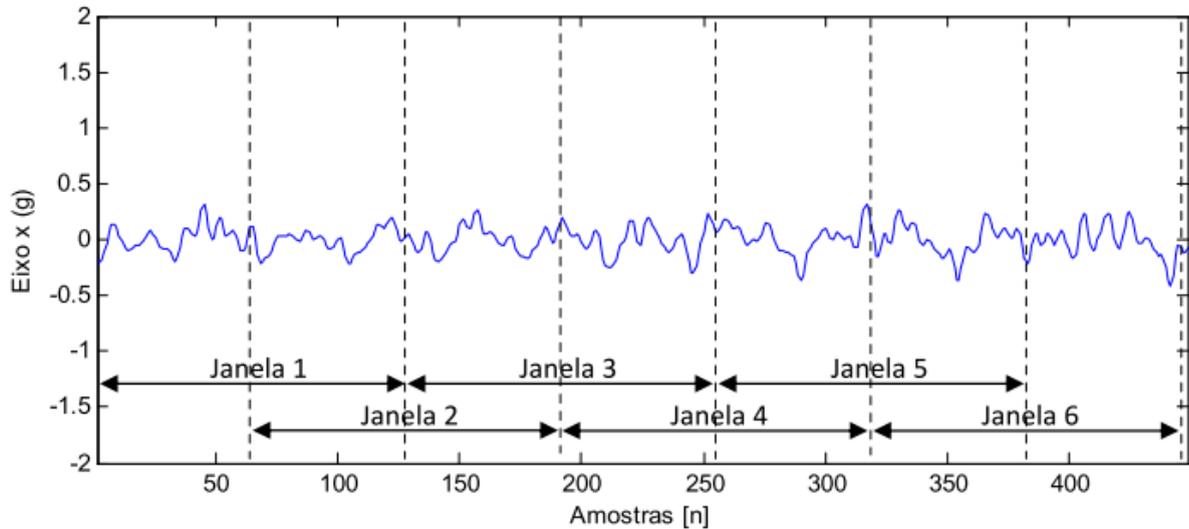


Figura 2.5 Exemplificação de segmentação de 2.56s ou 128 amostras/janela com *overlap* de 50%.

Na literatura há diferentes tamanhos de janelas sendo usados desde 0.08 segundos (BERCHTOLD et al., 2010) até mais que 30 segundos por ciclo (TAPIA et al., 2007).

Em sistemas RAH a segmentação de dados em janelas de tamanho fixo é também importante para um menor gasto de energia por parte dos sensores, já que os mesmos não precisariam ficar o tempo todo ligados, enviando dados para um servidor (LABRADOR; YEJAS, 2013).

2.5 EXTRAÇÃO DE CARACTERÍSTICAS

Com os dados coletados e pré-processados, a etapa seguinte é a extração de características que é uma abstração dos dados brutos capaz de representar as principais características dos mesmos. Essas características extraídas serão posteriormente repassadas para a etapa de identificação de atividades (SHOAIB et al., 2015).

Cada seguimento gerado a partir da etapa anterior do processo de RAH (pré-processamento dos dados) dá origem a algumas características. Para Bin Abdullah *et al.*(2012), as características podem ser classificadas em 4 categorias: características da magnitude, características da frequência, características da correlação e outras características.

As características da magnitude são as mais utilizadas pelos autores para RAH e a categoria engloba o valor da magnitude dos sensores como, por exemplo, o valor bruto dos eixos, média, desvio padrão, mínimo, máximo e média absoluta. As baseadas na frequência geralmente são extraídas a partir da Transformada Rápida de Fourier (do inglês, *Fast Fourier Transform* FFT) e abrangem a entropia, frequência máxima, energia, média e desvio padrão da FFT. As características da correlação caracterizam-se pelo uso da correlação entre os eixos ou outras características extraídas no processo (BIN ABDULLAH et al., 2012).

Em Figo *et al.* (2010), o autor classifica as características em 3 categorias: domínio do tempo, domínio da frequência e domínio discreto. As características podem ser extraídas do domínio do tempo através de métricas de matemática simples e estatísticas a partir de dados brutos dos sensores e são as mais utilizadas por algoritmos de RAH. As características do domínio da frequência são extraídas com o uso da FFT e vêm sendo amplamente utilizadas para capturar a natureza repetitiva do sinal de um sensor (SEFEN et al., 2016). A categoria do domínio discreto surgiu de um recente interesse em transformar sinais de acelerômetros e de outros sensores em uma palavra de símbolos discretos.

Em Lara e Labrador(2013) as características são compiladas para sinais de acelerômetro em 3 grupos principais: domínio do tempo, domínio da frequência e outras conforme ilustra a Tabela 2.2.

As características do domínio do tempo de do domínio da frequência vêm sendo amplamente utilizadas para buscar as principais informações nos sinais de acelerômetro e giroscópios (LE; NGUYEN, 2015).

Tabela 2.2 Grupos de características e métodos pelos quais as mesmas são extraídas.

Fonte: Adaptado de Lara e Labrador (2013)

Grupo	Métodos
Domínio do tempo	Média, desvio padrão, variância, desvio de média absoluta, correlação entre eixos e entropia
Domínio da frequência	Transformada de Fourier, Transformada Discreta de Cousine
Outras	<i>Principal Component Analysis</i> (PCA), <i>Linear Discriminant Analysis</i> (LDA) e modelos autoregressivos

Segundo Ortiz (2015) uma seleção de características pode ser aplicada nessa etapa a fim de se aumentar o desempenho na etapa de classificação. A seleção de características diz respeito ao processo de seleção do conjunto de características mais relevantes para o problema, diferenciando da extração de características que visa uma diminuição na dimensionalidade dos dados em relação aos dados originais. A vantagem de ambas é que reduzem a dimensionalidade do problema, permitindo que as atividades sejam mais facilmente diferenciadas entre si.

2.6 CLASSIFICAÇÃO DE ATIVIDADES

Após a extração de características, obtidas a partir de janelas de amostras dos sinais dos sensores, é necessário aplicar-se um algoritmo capaz de aprender os padrões contidos nesse conjunto de dados. Nesse sentido, algoritmos de Aprendizado de Máquina são utilizados nessa etapa, haja vista que são definidos como o processo de indução de uma hipótese ou de aproximação de uma função a partir da experiência passada (FACELI; LORENA, 2011).

Outra definição de AM descrita na literatura é como sendo o processo de desenvolvimento e avaliação de sistemas capazes de aprender a partir de dados (ORTIZ, 2015) ou ainda como a capacidade de descoberta de padrões a partir de um conjunto de dados (LABRADOR; YEJAS, 2013).

Geralmente algoritmos de AM são classificados em 3 grupos: aprendizado supervisionado, não supervisionado e semi supervisionado.

O aprendizado supervisionado diz respeito ao aprendizado cujas classes são rotuladas sob supervisão de forma manual (CHEN et al., 2011), por vídeo (ANGUITA et al., 2013) ou através de uma agenda de atividades (LARA et al., 2012), por exemplo. Já no aprendizado não supervisionado o algoritmo tenta descobrir sozinho relações, padrões, regularidades ou categorias nos dados que lhe vão sendo apresentados durante o treinamento.

A combinação dos aprendizados supervisionado e não supervisionado gera o grupo de aprendizado semi supervisionado no qual, normalmente, um pequeno grupo de classes devidamente rotuladas são integrados com um grande número de amostras sem rótulos durante o processo de aprendizagem.

Tabela 2.3 Tipos de algoritmos de AM mais utilizados em RAH

Algoritmo de AM	Trabalhos relacionados
Árvore de decisão	(ANJUM; ILYAS, 2013; BAYAT; POMPLUN; TRAN, 2014; FAN; WANG; WANG, 2013; LEE et al., 2015; SINGH; GARG, 2016; YAN; ABERER, 2012)
<i>Naive Bayes</i>	(LANE et al., 2011; MARTÍN et al., 2013; SEFEN et al., 2016; SHOAIIB et al., 2016)
k-NN	(CHETTY; WHITE, 2016; KOSE; INCEL; ERSOY, 2012; USTEV; INCEL; ERSOY, 2013)
SVM	(ORTIZ et al., 2016; ORTIZ, 2015; RAVI et al., 2005; SEFEN et al., 2016; STEWART et al., 2012)
Redes Neurais Artificiais	(AGUIAR et al., 2014; BAYAT; POMPLUN; TRAN, 2014; KWAPISZ; WEISS; MOORE, 2011; ONIGA; SUTO, 2014; ZHANG et al., 2013)

Os algoritmos de aprendizado supervisionado são referidos como classificação quando o rótulo das classes são discretos, sendo o tipo de AM mais utilizado para RAH (LABRADOR; YEJAS, 2013). A Tabela 2.3 exhibe os tipos de algoritmos mais utilizados para a criação de sistemas de RAH de acordo com a literatura e serão descritos brevemente a seguir.

Árvore de decisão: é um modelo de classificação baseado em uma estrutura hierárquica de regras no qual o problema é dividido em subproblemas de forma recursiva até que uma solução seja gerada, além disso são ferramentas de fácil entendimento e flexíveis. ID3 (QUINLAN, 1986) e C4.5 (QUINLAN, 1993) são os algoritmos mais comuns de árvores de decisão.

Naive Bayes: é um classificador baseado na teoria Bayesiana que tenta estimar a probabilidade de um dado ou padrão, representados por um conjunto de características, pertencentes à determinada classe.

k- Nearest Neighbors (k-NN): k- vizinhos mais próximos é um método determinístico de aprendizado que explora similaridades entre os k vizinhos mais próximos e os dados que se deseja classificar. Os k vizinhos mais próximos são identificados e é feita uma previsão da classe para determinado dado, sendo que as previsões de diferentes vizinhos são agregadas para realizar a classificação. Um dos problemas desse método é quando se tem uma alta dimensionalidade dos dados, uma vez que o vizinho mais perto, nesse caso, pode estar muito

distante. Há versões desse algoritmo que tratam desse problema com técnicas para redução na dimensionalidade.

Máquina de Vetores de Suporte ou *Support Vector Machine* (SVM): o objetivo desse método é encontrar o melhor hiperplano que separa dados de diferentes classes com a maior margem que for possível, de forma que a margem encontrada é a distância entre o dado que se deseja classificar e o hiperplano de separação.

Redes Neurais Artificiais (RNA): é uma abordagem de AM inspirada na biologia por trás do funcionamento dos neurônios. Neurônios artificiais são unidades de processamento interligados entre si que recebem uma entrada e através de um conjunto de pesos estimam uma saída. De forma geral tentam simular o funcionamento cérebro e as interconexões entre os neurônios para aprender e extrair conhecimento dos dados.

2.7 AVALIAÇÃO DO CLASSIFICADOR

Após desenvolvimento do sistema de classificação das atividades é necessário que a precisão do classificador seja avaliada com alguma técnica de medida de desempenho. Normalmente utiliza-se a medida de erro de precisão e análise da matriz de confusão para esta tarefa.

O desempenho deve ser calculado de forma que permita avaliar o poder de generalização durante a classificação de modo a evitar problemas como o sobreajuste, ou *overfitting*, que acontece quando o classificador é muito bom apenas para os dados que utilizou durante o treinamento e muito ruim quando apresentado dados ainda não vistos pelo mesmo.

Uma forma simples de se evitar sobreajuste é separando-se previamente os dados em dados de treinamento, validação e teste. Os dados de treinamento são utilizados para desenvolver o sistema classificador (treinamento), os dados de validação para análise da generalização do classificador e os dados de teste para avaliação do mesmo.

Pode-se ainda utilizar a validação cruzada para treinar o classificador com partes diferentes dos dados durante o treinamento e validação de forma recursiva até o final de n rodadas, e então avaliando-se a média dos resultados das n interações do processo.

A avaliação do classificador baseada no erro é obtida observando-se quantas predições o classificador f fez incorretamente, comparando-se a classe esperada de x_i , y_i , com a classe predita pelo classificador $f(x_i)$, sendo o erro obtido através da equação 2.1:

$$err(f) = \frac{1}{n} \sum_{i=1}^n I(y_i \neq f(x_i)) \quad (2.1)$$

A taxa de erro err varia entre 0 e 1, onde valores próximos de 0 representam melhores resultados (FACELI; LORENA, 2011).

Outra forma bastante comum de se avaliar o desempenho de um classificador é através da matriz de confusão. A matriz de confusão, como ilustrada na Figura 2.6 nos permite identificar de forma clara os tipos de erros ocorridos (falso positivo(FP) e falso negativo(FN)) e os tipos de acertos (verdadeiro positivo(VP) e verdadeiro negativo(VN)).

		Classe predita	
		+	-
Classe verdadeira {	+	VP	FN
	-	FP	VN

Figura 2.6 Matriz de confusão genérica.

Fonte: Adaptado de Faceli e Lorena(2011)

A acurácia ou taxa de acerto é o complemento da taxa de erro, podendo ser obtida pela equação 2.2 ou equação 2.3:

$$ac(f) = 1 - err(f) \quad (2.2)$$

$$ac(f) = \frac{VP+VN}{VP+VN+FP+FN} \quad (2.3)$$

Além do erro e análise da matriz de confusão para avaliação do desempenho, pode-se usar também outras medidas como precisão, sensibilidade e especificidade.

A precisão é a proporção de exemplos positivos classificados corretamente entre todos aqueles preditos como positivos sendo calculada através da equação 2.4:

$$prec(f) = \frac{VP}{VP+FP} \quad (2.4)$$

A sensibilidade corresponde à taxa de acerto na classe positiva, conforme a equação 2.5:

$$sens(f) = \frac{VP}{VP+FN} \quad (2.5)$$

Uma sensibilidade alta indica a capacidade de um sistema em classificar corretamente a atividade para casos positivos, ou seja, para os casos em que ela classificou que a atividade X era de fato a X , por exemplo.

Já a especificidade corresponde à taxa de acerto na classe negativa, de acordo com a equação 2.6:

$$esp(f) = \frac{VN}{VN+FP} \quad (2.6)$$

A especificidade indica a capacidade do sistema em indicar corretamente quando o sistema acusa que não é era a atividade X e de fato não era a X , por exemplo.

Considerando que VP, VN, FP e FN das Equações 2.3, 2.4, 2.5 e 2.6 referem-se a:

- VP corresponde ao número de verdadeiros positivos, ou ainda, ao número de amostras da classe positiva classificadas corretamente.
- VN corresponde ao número de verdadeiros negativos, isto é, ao número de amostras da classe negativa classificadas corretamente.
- FP corresponde ao número de falsos positivos, ou ainda, ao número de amostras cuja classe verdadeira é negativa, mas que foram classificadas incorretamente como pertencendo à classe positiva.
- FN corresponde ao número de falsos negativos, isto é, ao número de amostras que pertencem à classe positiva, mas que foram incorretamente classificados como da classe negativa.

3 REDES NEURAIS ARTIFICIAIS AUTO-ASSOCIATIVAS

3.1 CONSIDERAÇÕES INICIAIS

A realização de tarefas consideradas simples, como a realização de atividades físicas, a interação com o ambiente e o reconhecimento de objetos são possíveis, principalmente, pelo poder de processamento e aprendizado da estrutura biológica do cérebro humano. Inspirados nesse poder de aprendizado, em 1943, Warren McCulloch e Walter Pitts começaram a estudar a estrutura do cérebro visando utilizar o conhecimento obtido para o desenvolvimento de sistemas de aprendizado.

A partir de então, diversos pesquisadores vêm implementando e contribuindo para estruturas de Redes Neurais Artificiais (RNA) mais eficazes.

Neste capítulo serão apresentados alguns fundamentos básicos importantes a respeito de Redes Neurais Artificiais, sendo então introduzida a rede neural auto-associativa que é a rede utilizada para o desenvolvimento do sistema de RAH proposto neste trabalho.

3.2 REDES NEURAIS ARTIFICIAIS

As RNAs são sistemas computacionais distribuídos compostos de unidades de processamento simples (neurônios artificiais) que computam funções matemáticas, interconectadas e dispostas em uma ou mais camadas. Essas conexões, as sinapses, possuem um peso associado que ponderam a entrada recebida pelo neurônio. A Figura 3.1 exibe a estrutura básica de um neurônio artificial.

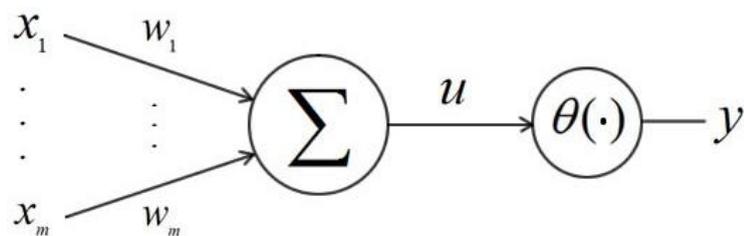


Figura 3.1 Estrutura básica de um neurônio artificial

O neurônio artificial computa uma função θ sobre a soma ponderada das m entradas gerando uma saída y dada pela equação 3.1:

$$y = \theta(\sum_{i=1}^m x_i w_i) \quad (3.1)$$

sendo x_i a i -ésima entrada para o neurônio, w_i o peso sináptico que pondera a entrada x_i e θ a função de ativação ou função de transferência.

As funções de ativação comumente utilizadas na literatura são: linear, limiar ou degrau e sigmoideal. O uso da função linear (Figura 3.2(a)) retorna como saída o valor de u . Na função limiar (Figura 3.2(b)) é definido o resultado da função como sendo 1 ou 0 de forma alternada (-1 também pode ser utilizado). A função sigmoideal (Figura 3.2(c)) é uma representação aproximada, contínua e diferenciável da função limiar.

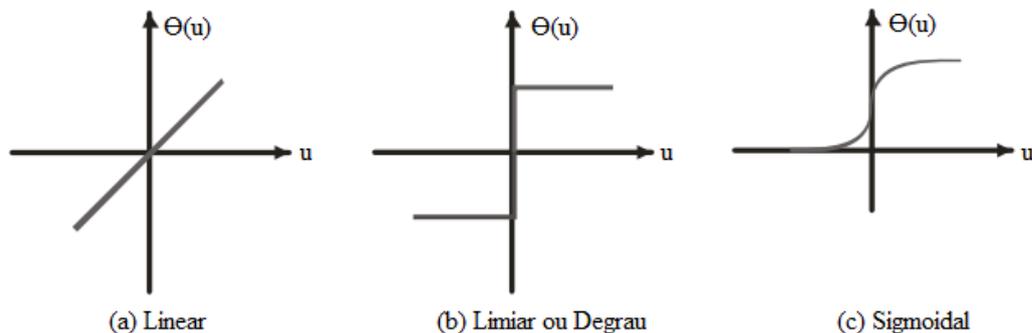


Figura 3.2 Funções de ativação que podem ser utilizadas por um neurônio artificial

Outro ponto importante no que diz respeito às RNAs é sobre o processo de aprendizado da rede. Segundo Bernarda *et al* (2000) o aprendizado é um processo pelo qual os parâmetros de uma rede neural são ajustados com o intuito de fazer com que o modelo obtenha melhor desempenho. O tipo de aprendizagem é determinada pela maneira pela que o ajuste dos parâmetros ocorre (HAYKIN *et al.*, 2009). Existem diversos algoritmos de treinamento que definem como o valor de cada peso deve ser alterado, geralmente sobre um conjunto específico de regras bem definidas.

Os principais paradigmas de aprendizado são supervisionado e não supervisionado. No aprendizado supervisionado as entradas e saídas são fornecidas por um supervisor cuja função é observar as respostas da rede para cada entrada e assim ajustar os parâmetros para que se possa encontrar uma ligação entre os dados de entrada e de saída. Já no aprendizado não supervisionado não há esse supervisor intervindo no processo, de tal forma que a rede deve aprender a partir de técnicas de agrupamento, por exemplo.

Um algoritmo supervisionado bastante relatado e utilizado na literatura para ajuste dos pesos é o algoritmo *Backpropagation* que utiliza amostras rotuladas (entrada e saída esperada) por meio de um mecanismo de correção de erros em duas etapas.

Na primeira etapa, chamada de *forward* ou ainda simplesmente de computação para frente, obtém-se a saída da rede através da amostra de entrada, processando os dados partindo-se da camada de entrada, passando pelas camadas intermediárias até alcançar a camada de saída. Na segunda etapa, chamada de *backward* ou computação para trás, é utilizado o erro (diferença entre a saída esperada e a saída obtida pela rede), para atualização dos pesos sinápticos da camada de saída até a primeira a camada intermediária (FACELI; LORENA, 2011; HAYKIN et al., 2009). Mais detalhes sobre o funcionamento interno do algoritmo e suas particularidades podem ser encontrados em Bernarda *et al.* (2000), Faceli e Lorena (2011) e Haykin *et al.* (2009).

Um problema que pode ocorrer e deve ser evitado no processo de aprendizado é o de super especialização, ou *overfitting*, no qual a rede fica especialista no conjunto de dados de treinamento e acaba perdendo o poder de generalização, gerando resultados ruins para novas amostras. Sendo assim, uma forma de se evitar o *overfitting* é através da validação cruzada, ou *cross validation*, em que os dados são divididos em 3 subconjuntos diferentes entre si: treino, validação e teste.

A cada interação do processo de treinamento o subconjunto de validação é submetido à rede para que se avalie o erro quadrático médio gerado entre a saída obtida e a saída desejada de modo que se o erro de validação começar a aumentar muito sem diminuir em determinado número de gerações (perda do poder de generalização), pode-se interromper o processo, ficando a critério do supervisor as modificações dos parâmetros da rede.

3.2.1 PERCEPTRON MULTICAMADAS

As redes *Perceptron* de Múltiplas Camadas (MLP do inglês *Multilayer Perceptron*) apresentam uma ou mais camadas intermediárias (ou ainda camada escondida) de neurônios e uma camada de saída. A função das camadas escondidas é intervir entre a camada de entrada e a de saída da rede de forma útil (HAYKIN et al., 2009). São consideradas redes aproximadoras universais, podendo realizar qualquer tipo de mapeamento linear ou não-linear entre as entradas e saídas de um determinado sistema.

A Figura 3.3 ilustra uma rede MLP totalmente conectada, onde todos os neurônios de uma camada estão conectados com os neurônios da camada seguinte.

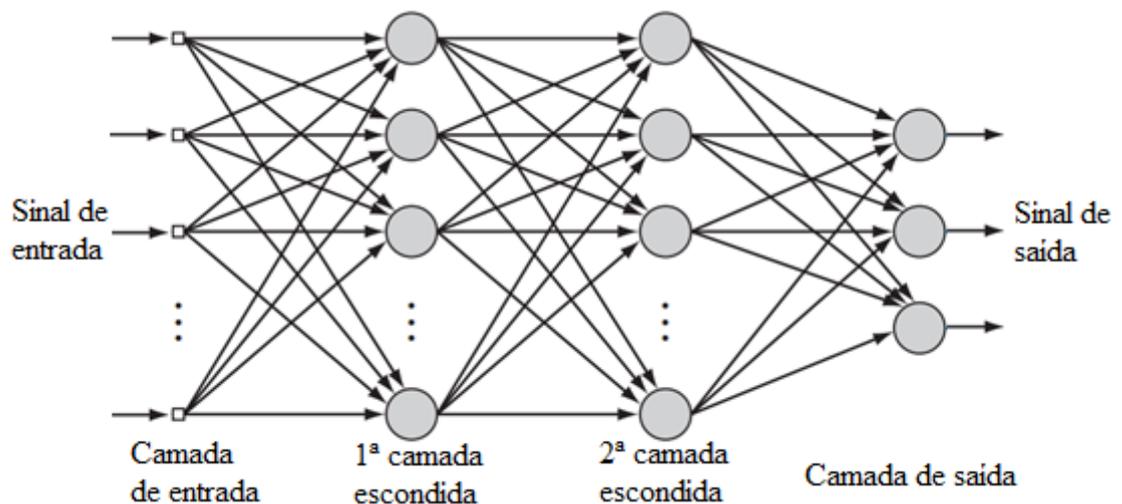


Figura 3.3 Arquitetura de uma rede MLP de duas camadas escondidas.

Fonte: Adaptado de Haykin *et al.*(2009)

A camada de entrada recebe o sinal de entrada e os envia para a camada seguinte. As camadas escondidas são responsáveis pelo processo de aprendizado que é feito através do processamento em cada neurônio. A função implementada por um neurônio de uma dada camada é uma combinação das funções processadas pelos neurônios da camada anterior que estão a ele ligados (FACELI; LORENA, 2011). A camada de saída recebe o resultado do processamento das camadas anteriores e fornece uma resposta relacionada a uma das classes presentes no conjunto de dados.

3.3 REDES NEURAIS ARTIFICIAIS AUTO-ASSOCIATIVAS

Uma Rede Neural Auto-Associativa (RNAA), representada na Figura 3.4, é um tipo especial de MLP na qual o número de entradas é igual ao número de saídas, sendo a rede treinada para realizar o mapeamento de identidade, onde a saída deverá ser aproximadamente igual a entrada (BALDI, 2012; BASCOL et al., 2016).

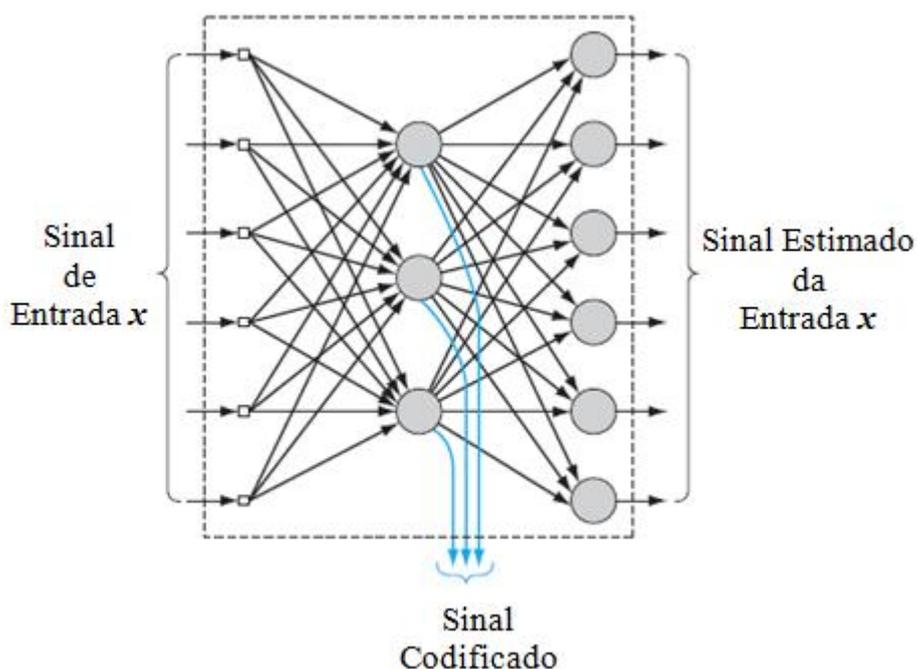


Figura 3.4 Ilustração de uma rede neural auto-associativa com camada intermediária com menos neurônios do que as camadas de entrada e saída.

Fonte: Adaptado de Haykin *et al.*(2009)

A camada intermediária ou de estrangulamento, geralmente contém menos neurônios que a camada de entrada e saída (nesse caso costuma ser chamada de *autoencoder*), e codifica as informações das entradas que serão posteriormente reconstruídas nas saídas. Se o treinamento da rede resultar em uma solução aceitável, de baixo erro, então a camada intermediária funciona como camada codificadora que permite que a rede armazene somente conhecimento relacionado às principais características do conjunto de dados de entrada.

As RNAAs foram inspiradas na Análise de Componentes Principais não Lineares (NLPCA, do inglês *Nonlinear Principal Component Analysis*)(KRAMER, 1991). A NLPCA é

uma técnica para análise multivariada de dados, similar ao método de Análise de Componentes Principais (PCA, do inglês *Principal Component Analysis*), e é usada para identificar e remover correlações entre variáveis de um problema, para auxílio na redução de dimensionalidade, para visualização e análise exploratória de dados.

Para Kramer (1991) a camada intermediária da rede auto-associativa pode ter tanto funções de ativação lineares como não lineares. Quando uma função linear é utilizada, o mapeamento de entrada para camada intermediária é similar ao da PCA, de forma que a informação é projetada ao longo da direção dos eixos ortogonais (autovetores) com a variância minimizada, e com grande perda de informação. Porém, quando a função de ativação é não linear, o mapeamento se torna semelhante ao da NLPCA gerando melhores características (MIRANDA; CASTRO; LIMA, 2012).

As RNAAs vêm geralmente sendo utilizadas para problemas de compressão de dados, extração de características, processamento digital de imagens e restauração de dados ausentes. No entanto, diversos trabalhos vêm sendo apresentados na literatura com RNAAs para problemas de classificação (CHAKROBORTY, 2013; IVERSEN; TAYLOR; BROWN, 2005, 2006, MIRANDA; CASTRO; LIMA, 2011, 2012).

No caso do uso das RNAAs para problemas de classificação, não existe a necessidade do número de neurônios na camada escondida ser menor do que da camada de entrada e saída. O que se almeja somente é a capacidade da RNAA de realizar o mapeamento de identidade, guardando em seus pesos as características dos padrões/dados utilizados para o treinamento da rede. Após o treinamento da rede, ao se apresentar para a rede padrões que não fazem parte da distribuição dos dados utilizados no treinamento, a rede não responderá adequadamente.

3.4 ESTADO DA ARTE DE REDES NEURAIS ARTIFICIAIS APLICADAS A RAH

Esta seção apresenta um panorama dos estudos relacionados a RAH através de RNAs, explicitando os trabalhos julgados mais relevantes.

No trabalho de Khan *et al.* (2010), com dados obtidos a partir de acelerômetro, foi proposto o reconhecimento de 15 atividades diferentes, inclusive as transições entre elas. A

acurácia obtida nesse trabalho foi de 97,90% utilizando MLP juntamente com método de autoregressão.

Em Silva G. (2013) , com dados obtidos a partir de acelerômetro, foi proposto o reconhecimento de 8 atividades diferentes. Nesse trabalho, além de outros métodos, foi utilizada uma MLP para a classificação das atividades com acurácia aproximadamente de 90,91%.

Em Bayat *et al.* (2014) são utilizados dados de acelerômetro de *smartphones* para fazer reconhecimento de 6 atividades humanas através de 6 classificadores diferentes, dentre eles uma MLP que apresentou melhor desempenho individual, sendo que o melhor desempenho global foi obtido utilizando a MLP em conjunto com *LogisticBoost* e SVM. A acurácia média obtida nesse trabalho foi de 91,15%.

No trabalho de Oniga e Suto (2014), através de uma RNA e dados obtidos a partir de acelerômetro e de um monitor cardíaco, se propõem um sistema de reconhecimento de 10 atividades humanas, 6 posturas dos braços, 5 posturas do corpo e atividades estáticas ou dinâmicas com o objetivo de auxílio para pacientes em tratamento. A acurácia do sistema desenvolvido foi de 99%.

Em Jiang (2015) são utilizados dados de acelerômetro e giroscópios de *smartphones* para gerarem imagens as quais serviram como entrada para redes neurais do tipo *Deep Convolutional Neural Networks* (DCNN). Para testarem a eficácia do método os autores utilizaram 3 bancos de dados públicos diferentes e além disso propuseram uma nova abordagem chamada de DCNN+ a qual obteve menor custo computacional se comparado à DCNN original e acurácia média de 98,45% para os 3 bancos de dados.

Em Safi *et al.* (2015) são utilizados dados de acelerômetro para fazer reconhecimento de 12 atividades humanas através de 7 classificadores diferentes, dentre quais uma MLP que apresentou resultado de 83.61% de acurácia.

Em Wang (2016) foram capturados dados de acelerômetro, giroscópio e magnetômetro de 8 voluntários. Os autores propuseram uma técnica baseada em *Continuous Autoencoders* (CAE) para a classificação de 19 diferentes atividades utilizando características extraídas dos sinais brutos de um ou mais sensores em conjunto. O melhor resultado, acurácia de 98,4%, foi obtido a partir da junção de dados de acelerômetro e magnetômetro.

Em Hammerla *et al.* (2016) foi utilizado *Convolutional Neural Networks* (CNN) para realizar a classificação de atividades de 3 bases de dados. Para uma das bases, composta de 12 atividades cujos sinais foram capturados com diversos sensores como acelerômetro, giroscópio e magnetômetro, o melhor resultado foi encontrado através da métrica F1-score de 93,7%.

4 REDES NEURIAS AUTO-ASSOCIATIVAS PARA RAH

4.1 CONSIDERAÇÕES INICIAIS

Como enfatizado na seção 2.1 o RAH é uma área de pesquisa importante e desafiadora, com muitas aplicações na área da saúde, ambientes inteligentes e segurança domiciliar e vem sendo estudada há anos, com pesquisadores da área propondo diferentes soluções para o problema (BAYAT; POMPLUN; TRAN, 2014; RASEKH; CHEN; LU, 2011). Através de RAH é possível criar sistemas que atuem nos mais variados tipos de ambientes, proporcionando inteligência aos mesmos.

Considerando a importância do desenvolvimento de sistemas de RAH, neste capítulo será apresentada uma nova metodologia para o reconhecimento de atividades.

O sistema de RAH proposto é baseado em Redes Neurais Auto-Associativas e foi desenvolvida com dados disponíveis em um banco de dados público de Anguita *et al.* (2013) que contém dados relacionados à seis atividades básicas: ficar de pé, sentado, deitado, caminhar, descer escadas e subir escadas. O banco de dados público foi gerado utilizando-se um *smartphone* para a captura dos sinais (sensores acelerômetros e giroscópio) e disponibiliza, além dos sinais, características extraídas no domínio do tempo e da frequência.

Vale ressaltar que outros bancos de dados de RAH como em Frank *et al.*(2010), Medrano *et al.* (2014) e Vavoulas *et al.* (2013), além do utilizado neste trabalho, estão sendo disponibilizados por seus autores para facilitar as comparações de eficiência entre metodologias propostas para RAH. Porém utilizamos este banco de dados por ser bastante completo, não possuir dados ausentes e ser muito relatado pela comunidade científica, além disso esta base foi validada em uma competição realizada em uma sessão especial de "*Human and Motion Disorder Recognition at the European Symposium on Artificial Neural Networks*" em 2013.

Este capítulo inicialmente faz uma descrição detalhada da base de dados utilizada. Em seguida a metodologia é descrita, seguindo então a discussão dos resultados obtidos.

4.2 BASE DE DADOS

A base de dados utilizada neste trabalho foi obtida em Anguita *et al.* (2013), fonte dos trabalhos em Anguita *et al.* (2013), Kastner *et al.* (2013), Ortiz *et al.* (2016), Ortiz (2015), Reiss *et al.* (2013) e Romera-Paredes *et al.* (2013). Existem duas versões desta base, sendo que a primeira versão, a qual é a utilizada nesta dissertação, é composta por seis atividades básicas que são o foco dessa pesquisa, enquanto que a segunda versão possui, além das seis atividades básicas, movimentos de transição entre uma atividade e outra.

A seguir será dada uma breve descrição sobre como foi realizada a captura dos dados e o pré-processamento, sendo que para mais detalhes (ANGUITA *et al.*, 2013) pode ser consultado.

Os experimentos para captação dos dados foram realizados com um grupo de 30 voluntários com idades entre 19-48 anos. Os voluntários realizaram um protocolo composto por 6 atividades básicas: 3 posturas estáticas (ficar de pé, sentado e deitado) e 3 atividades dinâmicas (caminhar, descer escadas e subir escadas).

Foram capturadas a aceleração e a velocidade angular a uma taxa constante de 50 Hz, utilizando o acelerômetro e o giroscópio de um *smartphone*, o qual permaneceu na cintura dos voluntários durante a execução do experimento. As atividades foram rotuladas manualmente através de gravação em vídeo dos experimentos.

Os sinais obtidos de ambos os sensores (acelerômetro e giroscópio) foram pré-processados em um janelamento de 2.56s com sobreposição de 50%, isto é, 128 amostras/janela. A Figura 4.1 ilustra uma janela (128 amostras) do comportamento dos sinais brutos dos 3 eixos do acelerômetro para a atividade Caminhar.

Em seguida os sinais foram filtrados utilizando-se um filtro passa-baixa de 3^a ordem *Butterworth* com frequência de corte de 20Hz afim de se eliminar ruídos.

Considerando que o sinal da aceleração capturado sofreu influência da constante gravitacional ($9.81 \text{ m/s}^2 = 1\text{g}$), o sinal da aceleração foi separado em aceleração do corpo e gravidade utilizando um filtro passa-baixa com frequência de corte de 0.3 Hz.

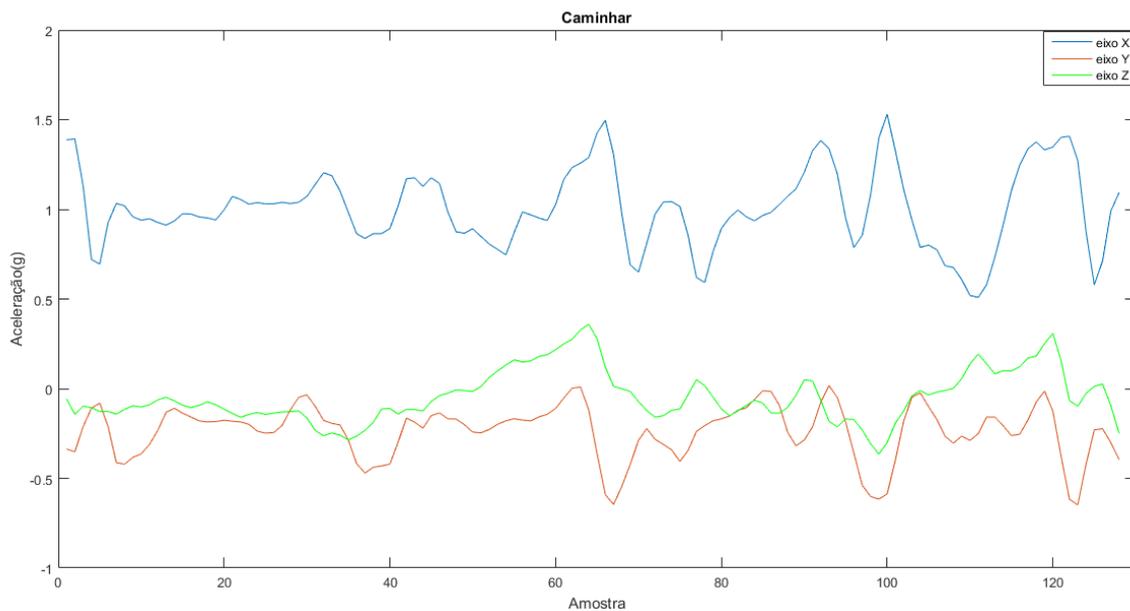


Figura 4.1 Janela com 128 amostras da atividade Caminhar

Após esse processo, para cada janela de sinal (considerando os sinais dos 3 eixos do acelerômetro e giroscópio), foram extraídas características do domínio do tempo e da frequência de componentes dos sinais, totalizando 561 características devidamente normalizadas no intervalo de $[-1 \ 1]$ conforme a equação 4.1 :

$$xNorm = \frac{x - Min}{Max - Min} * 2 - 1 \quad 4.1$$

onde $xNorm$ é a característica normalizada, x é a característica em si, e Min , Max são os valores mínimo e máximo da característica. As características foram extraídas a partir de funções listadas na Tabela 4.1.

No geral a base contém 10299 padrões, cada um contendo as 561 características extraídas e fora dividido de forma aleatória em 2 grupos, um para treinamento com 70% do total dos dados e 30% para teste (ANGUITA et al., 2013).

Tabela 4.1 Lista de Funções para extração das variáveis.

Fonte: Adaptado de Anguita *et al.*(2013)

Função	Descrição	Formulação	Domínio
Mean()	Média aritmética	$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$	Tempo
Std()	Desvio padrão	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2}$	Tempo
Mad()	Desvio absoluto médio	$median_i(s_i - median_j(s_j))$	Tempo
Max()	O maior valor de um vetor	$max(s_i)$	Tempo
Min()	O menor valor de um vetor	$min(s_i)$	Tempo
Skewness()	Assimetria da frequência	$E \left[\left(\frac{s - \bar{s}}{\sigma} \right)^3 \right]$	Freq
Kurtosis()	Curtose da frequência	$\frac{E[(s - \bar{s})^4]}{E[(s - \bar{s})^2]^2}$	Freq
MaxfreqInd(s)	Índice da frequência com maior amplitude	$\arg max_i (s_i)$	Freq
Energy	Medida de Energia	$\frac{1}{N} \sum_{i=1}^N s_i^2$	Tempo
SMA()	Sinal Magnitude Área	$\frac{1}{3} \sum_{i=1}^3 \sum_{j=1}^N s_{i,j} $	Tempo
Entropy()	Medida de Entropia	$\sum_{i=1}^N (c_i \log(c_i)), c_i = \frac{s_i}{\sum_{j=1}^N s_j}$	Tempo
Iqr()	Varição Interquartile	$Q3(s) - Q1(s)$	Tempo
Autoregression()	Coefficiente de Autoregressão	$a = arburg(s, 4), a \in R^4$	Tempo
Correlação()	Coefficiente de Correlação de Pearson	$C_{1,2} / \sqrt{C_{1,1} C_{2,2}}, C = cov(s_1, s_2)$	Tempo
MeanFreq()	Média ponderada dos componentes de frequência	$\sum_{j=1}^N i s_i / \sum_{j=1}^N s_j$	Freq
EnergyBand()	Energia de um intervalo de frequência	$\frac{1}{a - b + 1} \sum_{i=a}^b s_i^2$	Freq
Angle()	Ângulo entre os vetores	$\tan^{-1}(\ [\bar{s}_1, \bar{s}_2, \bar{s}_3] \times v\ , [\bar{s}_1, \bar{s}_2, \bar{s}_3])$	Tempo

As componentes dos sinais presentes nesta base são:

1. Aceleração do corpo sem a influência da gravidade;
2. Velocidade angular do corpo;
3. Aceleração dos eixos devido ao movimento do corpo com a influência da gravidade presente no sinal;
4. Derivada da aceleração do corpo dos eixos;
5. Derivada da velocidade angular do corpo dos eixos;
6. Magnitudes dos sinais obtidas pela norma euclidiana conforme:
 - a. magnitude da aceleração do corpo;
 - b. magnitude da velocidade angular do corpo;
 - c. magnitude da aceleração com efeito da gravidade;
 - d. magnitude da derivada da aceleração do corpo;
 - e. magnitude da derivada da velocidade angular do corpo;
7. Através da aplicação de Transformada Rápida de *Fourier* (ou *Fast Fourier Transform* (FFT)) foram extraídas as variáveis do domínio da frequência:
 - a. frequência da aceleração do corpo dos eixos;
 - b. frequência da velocidade angular do corpo dos eixos;
 - c. frequência da derivada da aceleração do corpo dos eixos;
 - d. frequência da magnitude da aceleração do corpo dos eixos;
 - e. frequência da magnitude da velocidade angular do corpo;
 - f. frequência da magnitude da derivada da aceleração do corpo;
 - g. frequência da magnitude da derivada da velocidade angular do corpo;
8. Foram calculados ainda os ângulos entre os vetores:
 - a. média da aceleração do corpo e média da gravidade;
 - b. média da derivada da aceleração do corpo e média da gravidade;
 - c. média da velocidade angular do corpo e média da gravidade;
 - d. média da derivada da velocidade angular do corpo e média da gravidade;
 - e. eixo X e média da gravidade;
 - f. eixo Y e média da gravidade;
 - g. eixo Z e média da gravidade.

O autor da base dividiu a mesma em 5 subconjuntos afim de organizar a divisão das variáveis de acordo com o domínio de extração e com os sensores utilizados. Os subconjuntos são:

- D1: dados de acelerômetro no domínio do tempo, contendo 17 variáveis mais utilizadas na literatura conforme Anguita *et al.*(2013) extraídas de funções de Média, Correlação, SMA e Entropia.
- D2: dados de acelerômetro e giroscópio no domínio do tempo e da frequência, contendo todas as 561 variáveis extraídas.
- D2T: dados de acelerômetro e giroscópio apenas no domínio do tempo, contendo 272 variáveis extraídas.
- D3: dados de acelerômetro e giroscópio no domínio do tempo e da frequência, contendo todas as 561 variáveis extraídas. Essa base faz parte da versão 2 da mesma e conta ainda com transições entre atividades estáticas.
- D3T: Dados de acelerômetro e giroscópio apenas no domínio do tempo, contendo 272 variáveis extraídas. Essa base faz parte da versão 2 da mesma e conta ainda com transições entre atividades estáticas.

4.3 SISTEMA PARA RECONHECIMENTO DE ATIVIDADES HUMANAS

O sistema proposto pretende realizar o reconhecimento de seis atividades básicas: 3 posturas estáticas (ficar de pé, sentado, deitado) e 3 atividades dinâmicas (caminhar, descer escadas e subir escadas). Duas abordagens serão realizadas de modo a analisar a aplicabilidade de RNAs para o problema de RAH.

Ambas abordagens consistem em criar um sistema que reconheça as 6 atividades da base utilizando redes neurais artificiais do tipo *Perceptron* de Múltiplas Camadas auto-associativa (RNA), diferindo entre si apenas pela entrada do sistema.

Na primeira abordagem, chamada de cenário 1, foram utilizados como entrada os dados de características do domínio do tempo extraídas do sinal capturado através de um *smartphone* (banco de dados D2T - sinais de acelerômetros e giroscópio). Na segunda

abordagem, chamada de cenário 2, foram utilizados como entrada os dados brutos dos eixos X, Y e Z da aceleração do corpo no domínio do tempo.

No cenário 1, optou-se pela utilização do banco de dados DT2 pelo motivo do mesmo possuir apenas características extraídas no domínio do tempo. No caso do cenário 2, optou-se trabalhar com o sinal bruto, para se verificar a eficiência do sistema RAH, sem a necessidade de extração de características do sinal no domínio do tempo ou da frequência.

Como já mencionado na seção 4.2 o sinal da aceleração do corpo é o sinal bruto da movimentação do corpo sem a influência da constante gravitacional, já que segundo Labrador e Yejas (2013), Lara e Labrador (2013), Ortiz (2015) e Sefen *et al.*(2016) a mesma adiciona ruídos excessivos nos sinais de atividades humanas, podendo atrapalhar no processo de RAH. Portanto, decidiu-se utilizar os dados da aceleração do corpo no cenário 2, por estes representarem de forma digna os movimentos das atividades realizadas por determinada pessoa.

A Figura 4.2 ilustra de forma genérica o esquema do sistema de RAH proposto para ambos cenários.

O sistema funcionará recebendo o padrão (dados de entrada) para um determinado sinal capturado pelo *smartphone*, após passar pelo processo de janelamento e extração de características no domínio do tempo, no caso do cenário 1 e amostras do sinal bruto no caso do cenário 2. Os dados servirão como entrada simultânea para as seis RNAs, sendo que cada RNA foi, numa etapa anterior, treinada para cada caso de atividade. Essa abordagem é chamada de máquinas de comitê onde combina-se estimadores, nesse caso as RNAs treinadas, visando melhorar o desempenho final de classificação, já que estimadores combinados geralmente apresentam melhor generalização e robustez .

Após a apresentação da entrada para todas as redes, cada uma calcula as suas saídas. O cálculo do erro médio quadrático entre as entradas e saídas de cada rede deverá ser realizado. A RNA que apresentar menor erro quadrático médio será considerada como a rede vencedora e conseqüentemente o padrão apresentado na entrada do sistema será classificado de acordo com a atividade atribuída à esta rede vencedora.

O sistema é baseado na capacidade de cada RNA, treinada para cada tipo de atividade, de realizar o mapeamento de identidade, onde seus pesos guardam as características da distribuição dos padrões utilizados para o treinamento da rede. Após o treinamento de cada

RNAA para cada tipo de atividade, ao se apresentar para as mesmas padrões que não fazem parte de sua distribuição de dados de treinamento, a rede não responderá adequadamente, apresentando um erro médio quadrático entre entrada e saída com valor alto.

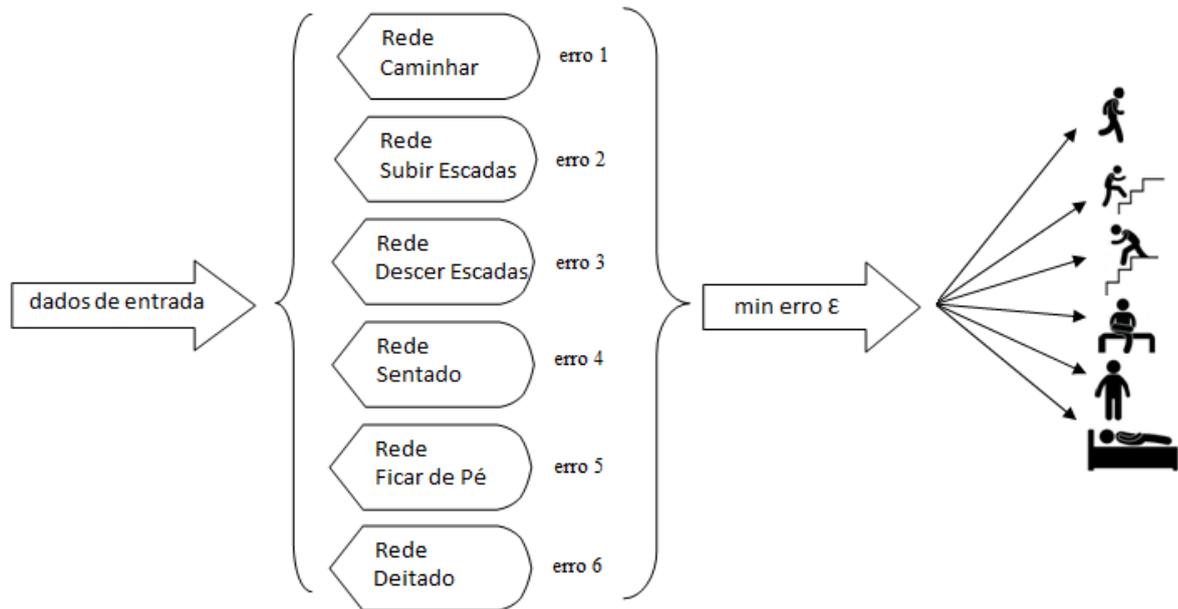


Figura 4.2 Ilustração do sistema de RAH baseado em 6 redes auto-associativas

Cada uma das 6 redes RNAA foi treinada com função de ativação não linear sigmoidal para os neurônios da camada intermediária e função linear para os neurônios na camada de saída. Diversos treinamentos foram realizados, utilizando-se MATLAB, com diferentes números de neurônios na camada intermediária para todas as redes. O algoritmo de treinamento utilizado em ambos cenários foi o *Scaled Conjugate Gradient*. Este algoritmo foi escolhido por ser mais adequado no que diz respeito a problemas de memória computacional (BEALE; HAGAN; DEMUTH, 2015).

Os cenários e os resultados obtidos por cada um deles serão descritos nas subsecções a seguir. A avaliação do desempenho de cada resultado foi medido através da acurácia, sensibilidade, especificidade e pela análise da matriz de confusão, descritos na seção 2.7, que são métodos de avaliação bastante relatados e utilizados na literatura inclusive para problemas de RAH (FACELI; LORENA, 2011; KWAPISZ; WEISS; MOORE, 2011; LABRADOR; YEJAS, 2013; ORTIZ, 2015; SAN-SEGUNDO et al., 2016).

4.3.1 CENÁRIO 1

Nesse cenário seis RNAs foram treinadas, uma para cada tipo de atividade, possibilitando assim que cada RNA aprenda a distribuição dos dados característicos de cada atividade. As entradas e saídas para cada RNA foram as 272 características pertencentes ao subconjunto D2T.

Após exaustivos treinamentos na busca das melhores topologias para as RNAs que levassem o sistema de RAH a uma taxa de acerto satisfatória, obtiveram-se as topologias de 272-100-272 (número de neurônios na camada de entrada, escondida e saída respectivamente) para as redes das atividades caminhar, subir escadas, descer escadas e deitado e as topologias de 272-200-272 para as atividades de ficar de pé e sentado. A Figura 4.3 ilustra a topologia das RNAs treinadas, onde cada rede pode ser representada como contendo 272 entradas/saídas com 100 ou 200 neurônios na camada oculta, dependendo da atividade treinada. Silva C.(2013) ressalta que a variação dos sinais da aceleração para atividades estáticas é praticamente nula, podendo-se assim explicar a necessidade de um número maior de neurônios para as redes treinadas para as atividades ficar de pé e sentado.

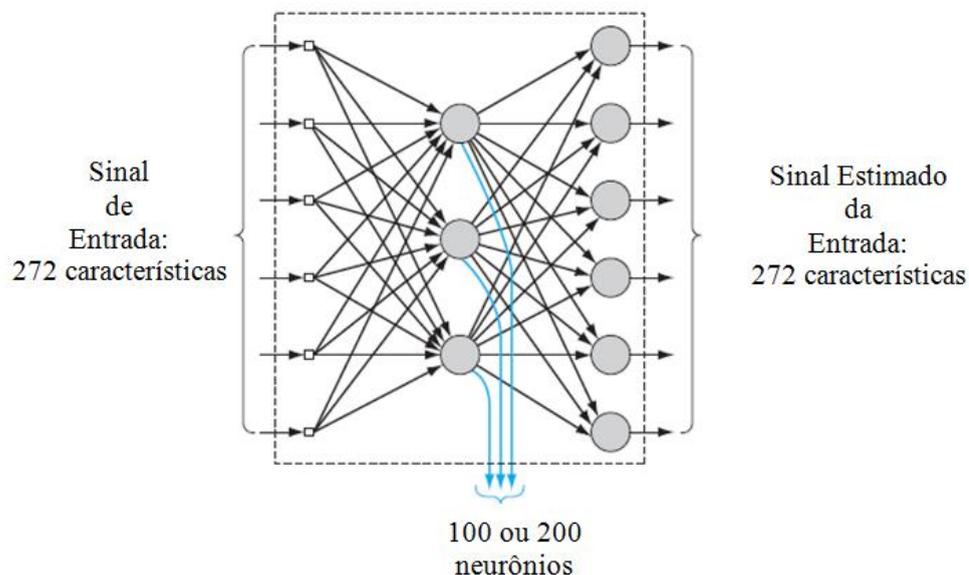


Figura 4.3 Ilustração genérica das RNAs treinadas para cada atividade no cenário 1

É importante salientar aqui que como o objetivo é apenas a reprodução das amostras da entrada da rede na saída da mesma, não existe então a restrição para a RNA do número

de neurônios na camada escondida ser menor que o número de neurônios na camada de entrada e saída.

Cada treinamento fora realizado com validação cruzada, conforme detalhado na seção 3.2, onde divide-se o conjunto de dados em 3 três subconjuntos: treino (para ajuste dos pesos, 60% das amostras), validação (evitar *overfitting* , 10% das amostras) e teste (verificar poder de generalização, 30% das amostras).

Após o treinamento, validação e teste das seis RNAs, foram apresentados para o sistema RAH, na configuração da Figura 4.2, todos os dados que foram anteriormente utilizados para treino, validação e teste de todas as redes. O sistema de reconhecimento de atividades humanas proposto nesse cenário apresentou uma acurácia de 98,69% quando apresentado todos os dados disponíveis, apresentando uma acurácia para dados de treino de 99,43% e de 97,09% para os dados de validação. No caso dos dados de teste, composto de 3090 padrões, apresentou uma acurácia de 97,73%.

A Tabela 4.2 nos mostra a matriz de confusão para o sistema de classificação para esse cenário considerando apenas os dados de teste, exibindo também a acurácia, a sensibilidade e a especificidade do sistema.

Tabela 4.2 Matriz de confusão para a base de testes cenário 1

Atividade	AT1	AT2	AT3	AT4	AT5	AT6	Sensibilidade (%)	Especificidade (%)
AT1	512	5	0	0	0	0	99,03	99,80
AT2	0	463	0	0	0	0	100	99,53
AT3	5	4	413	0	0	0	97,86	100
AT4	0	0	0	499	34	0	93,62	99,25
AT5	0	2	0	19	551	0	96,32	98,64
AT6	0	1	0	0	0	582	99,82	100
Acurácia								97,73

AT1 = Caminhar, AT2 = Subir Escadas, AT3 = Descer Escadas, AT4 = Sentado, AT5 = Ficar de Pé e AT6 = Deitado

A acurácia foi calculada somando-se os valores da diagonal principal da matriz de confusão (que indica o número de acertos para cada atividade) e dividindo este valor pelo número total de padrões de teste apresentados ao sistema RAH conforme descrito na seção 2.7. A sensibilidade e a especificidade são medidas de desempenho para se calcular a taxa de acertos na classe positiva e a taxa de acertos na classe negativa respectivamente.

Uma sensibilidade alta indica a capacidade do sistema em classificar corretamente determinada atividade para casos positivos, isto é, para os casos em que foi classificado que a

AT1 era de fato a AT1, por exemplo. A especificidade indica a capacidade do sistema em indicar corretamente quando o sistema acusa que não era a AT1 e de fato não era a mesma, por exemplo.

Pela análise da matriz de confusão podemos notar onde o sistema teve maior dificuldade na distinção correta entre uma atividade e outra. As atividades AT4 e AT5 são as mais confundidas entre si pelo sistema, com a menor taxa de sensibilidade para AT4 e logo em seguida para AT5. Segundo Silva C.(2013) a variação dos sinais da aceleração para atividades estáticas é quase nula, explicando dessa forma a maior confusão entre essas atividades.

4.3.2 CENÁRIO 2

Nesse cenário também foram treinadas seis RNAs, uma para cada tipo de atividade, de modo que cada RNA pôde aprender a distribuição dos dados característicos de cada atividade.

As entradas e saídas para cada RNA foram os dados dos eixos X, Y e Z da aceleração do corpo, exemplificado na Figura 4.1, sendo assim, a entrada para cada rede foi uma matriz de 128 (número de amostras por janela) vezes 3 (número de eixos do acelerômetro), resultando em 384 amostras que foram normalizadas entre [0 1], conforme ilustrado na Figura 4.4, que representa o sinal de entrada e o de saída (entrada estimada) para cada rede treinada, onde N representa o número de neurônios na camada oculta que varia de acordo com a topologia da rede.

O objetivo em se utilizar os dados brutos da aceleração do corpo é de mostrar a capacidade das RNAs em lidar com os sinais sem processamento prévio o qual em sistemas de RAH pode representar uma redução de custo de processamento e tempo antes da classificação propriamente dita. Isso pode ser vantajoso para sistemas implementados em ambientes reais, onde a reposta deve ser rápida o suficiente para a tomada de decisão, mas que o consumo de energia e poder computacional de processamento são limitados como em *smartphones*.

Esse cenário diferencia-se das metodologias já utilizadas na literatura por lidar com os dados brutos da aceleração do corpo dos sinais através de RNA, explorando a capacidade da

mesma em realizar o mapeamento de identidade das características dos padrões utilizados para o treinamento da rede.

Os trabalhos correlatos relatados na seção 3.4 também fazem uso de redes neurais para o RAH, como através de MLP (BAYAT; POMPLUN; TRAN, 2014; ONIGA; SUTO, 2014; SILVA G., 2013), de rede neural do tipo DCNN+ (JIANG, 2015), ou ainda de CAE (WANG, 2016) e utilizam as características extraídas pela fase do pré-processamento. Por outro lado a metodologia aqui apresentada utiliza a porção dos dados de acelerômetro correspondentes à aceleração do corpo, apenas separada do efeito da gravidade, sem passar por processo extrator de características, tornando a metodologia proposta uma alternativa interessante para a criação de sistemas de RAH utilizando dados capturados com acelerômetros.

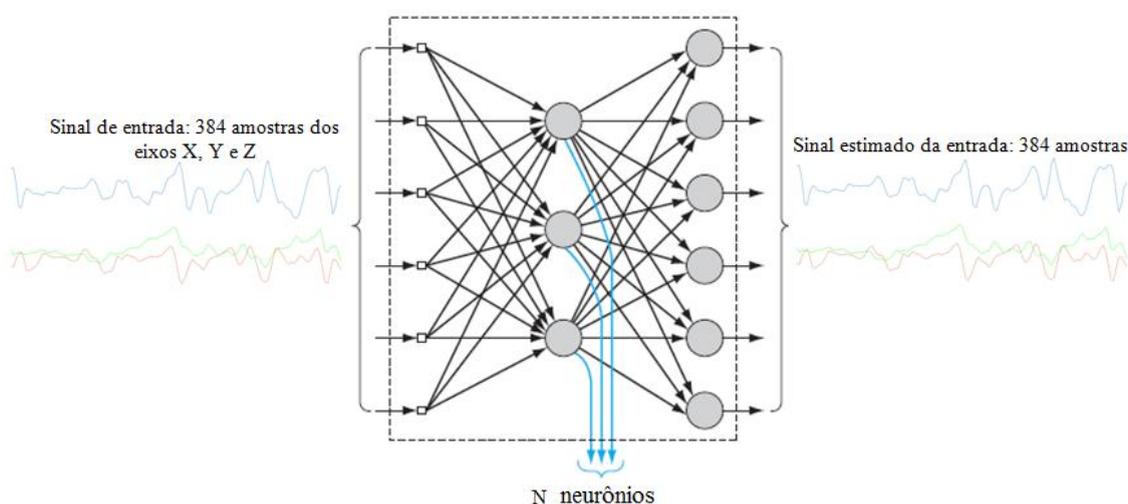


Figura 4.4 Ilustração genérica das RNAs treinadas para cada atividade no cenário 2

Cada treinamento foi realizado com validação cruzada, conforme detalhado na seção 3.2, onde divide-se o conjunto de dados em 3 três subconjuntos tal que 60% das amostras foram separadas para o treinamento, 10% para a validação e 30% para o teste das redes. Tal distribuição é a mesma utilizada pela validação da base de dados (descrito na seção 4.1), desse modo facilita-se a comparação com os resultados de outros trabalhos.

Após diversos treinamentos em busca de um conjunto de topologias para as RNAs que fizessem com que o sistema de RAH respondesse com uma taxa de acerto satisfatória, foram obtidas as topologias de 384-90-384 (número de neurônios na camada de entrada, escondida e saída respectivamente) para as redes das atividades caminhar e subir escadas, topologias de 384-110-384 para descer escadas, topologias de 384-160-384 para as atividades

deitado e ficar de pé e finalmente a topologia de 384-300-384 para a atividade sentado. A Figura 4.4 ilustra esse cenário, onde cada rede pode ser representada como contendo 384 entradas/saídas com N neurônios na camada oculta, onde N pode ser 90, 110, 160 ou 300 dependendo da atividade treinada.

Após o treinamento, validação e teste das seis RNAAs, foram apresentados para o sistema RAH, na configuração da Figura 4.2, todos os dados que foram anteriormente utilizados para treino, validação e teste de todas as redes. O sistema de reconhecimento de atividades humanas proposto nesse cenário apresentou uma acurácia de 98,26% para dados de treino, de 98,09% para os dados de validação. No caso dos dados de teste, apresentou uma acurácia de 95,70%.

Através da análise da Tabela 4.3 que nos mostra a matriz de confusão para o cenário 2, considerando os dados de teste, podemos notar que houve maior dificuldade entre as atividades estáticas deitado e sentado, isso explica-se pelo fato das atividades estáticas terem sinais muito próximos uns dos outros (ORTIZ, 2015), com pouca variância, motivo pelo qual se pode explicar também a grande diferença entre o número de neurônios na camada intermediária utilizados para as topologias dessas redes.

Tabela 4.3 Matriz de confusão para a base de testes no cenário 2

Atividade	AT1	AT2	AT3	AT4	AT5	AT6	Sensibilidade (%)	Especificidade (%)
AT1	480	5	11	0	0	0	96,77	100,00
AT2	0	444	27	0	0	0	94,26	99,10
AT3	0	15	405	0	0	0	96,42	98,50
AT4	0	3	0	484	4	0	98,57	100,00
AT5	0	0	0	0	527	5	99,00	97,50
AT6	0	0	0	0	58	479	90,00	99,80
Acurácia								95,70

AT1 = Caminhar, AT2 = Subir Escadas, AT3 = Descer Escadas, AT4 = Sentado, AT5 = Ficar de Pé e AT6 = Deitado

Novamente a acurácia foi calculada somando-se os valores da diagonal principal da matriz de confusão (que indica o número de acertos para cada atividade) e dividindo este valor pelo número total de padrões de teste apresentados ao sistema RAH conforme descrito na seção 2.7. Também foram calculadas a sensibilidade e a especificidade que são medidas de desempenho para se calcular a taxa de acertos na classe positiva e a taxa de acertos na classe negativa respectivamente.

A sensibilidade alta da matriz de confusão da Tabela 4.3 indica que o sistema proposto é capaz de classificar corretamente determinada atividade para casos positivos, isto é, para os casos em que foi classificado que a AT1 era de fato a AT1, por exemplo. Já a especificidade alta da matriz indica a capacidade do sistema proposto em apontar corretamente quando o sistema acusa que não era a AT1 e de fato não era a mesma, por exemplo.

4.4 RESULTADOS E DISCUSSÃO

O sistema proposto consistiu em realizar o reconhecimento de 6 atividades básicas utilizando RNAs de modo a analisar a aplicabilidade das mesmas para o problema de RAH. Para isso 2 cenários foram criados. No cenário 1 foi utilizado, como entrada para o sistema de RAH, 272 características provenientes do domínio do tempo extraídas do sinal capturado com acelerômetro e giroscópio de um *smartphone*. Já no cenário 2 foi utilizado como entrada 384 amostras dos dados brutos da aceleração do corpo no domínio do tempo. Em ambos os cenários a classificação do sistema proposto foi feita através da comparação dos erros médios quadráticos produzidos por cada uma das seis redes treinadas.

No cenário 1 foi obtida a taxa de acerto de 97,73% e assim como nesse cenário o trabalho de Ortiz (2015) utilizou as 272 variáveis do subconjunto D2T e, através de L1-SVM e L2-SVM, e obteve uma acurácia para dados de teste entre 96,30% e 96,91%. Pela análise do resultado é possível reforçar a validade do sistema aqui proposto para lidar com as características extraídas no domínio do tempo.

Além disso, pela análise dos resultados no cenário 2, pôde-se mostrar o poder das RNAs em lidar com o mapeamento de identidade de dados brutos da aceleração do corpo, onde se obteve uma taxa de 95,70% para a base de teste, o que é um resultado satisfatório e muito próximo dos resultados obtidos por trabalhos que também utilizaram a mesma base, mas com técnicas que utilizaram as características extraídas (as 561 disponíveis na base) como o de Kastner *et al.* (2013), o de Reiss *et al.* (2013) e o de Romera-Paredes *et al.* (2013) com acurácia para dados de teste de 96,23%, 94,33% e 96,40% respectivamente, enquanto que o autor da base obteve, através de SVM, uma acurácia de 96,50%.

A utilização de dados brutos da aceleração do corpo ainda é pouca explorada na literatura e autores como Lara e Labrador (2013) e Ortiz (2015) relatam a dificuldade de lidar

com dados assim pelo fato de possuírem grande quantidade de ruído. Desta forma a maioria dos trabalhos relacionados ao RAH utiliza-se de algum método extrator de características para o sistema classificador.

O método aqui apresentado é bastante vantajoso, por exemplo, em sistemas de reconhecimento de atividades em tempo real onde a resposta deve ser rápida o suficiente para a tomada de decisão e também quando o consumo de energia e poder computacional de processamento são limitados como em *smartphones*, que ao invés de ficar capturando os dados, extraíndo características para depois realizar a classificação em si, poderia poupar energia e processamento, apenas capturando os dados já sem a influência da gravidade e classificando as atividades mais rapidamente.

O bom resultado apresentado pelo sistema de RAH proposto mostra a grande aplicabilidade de RNNAs para problemas de classificação, mostrando assim sua eficiência não só para problemas de compressão de sinais (onde estas redes vêm sendo mais utilizadas) mas também para problemas onde se possa utilizar a capacidade de mapeamento de identidade da RNAA como no de classificação de atividades.

5 CONCLUSÃO

O objetivo desta dissertação foi apresentar uma nova abordagem baseada em Redes Neurais Auto-associativas para o reconhecimento de atividades humana, utilizando dados obtidos com sensores de *smartphone*.

A principal motivação para uso de RNAA para este problema, é que apesar da literatura apresentar diversos trabalhos com redes neurais que alcançam bons resultados, não foram encontrados correlatos utilizando RNAA para o problema de reconhecimento de atividades humanas que utilizassem dados brutos.

O problema de RAH foi contextualizado apresentando-se os principais conceitos relacionados a RAH, as etapas para a criação de um sistema classificador de atividades humanas e as aplicações de RAH nas mais diversas áreas.

As dificuldades encontradas nesta pesquisa estão relacionadas ao entendimento do domínio de forma geral, pois há poucos trabalhos que conceituam de maneira formal o problema de RAH. Além disso, nas etapas de RAH são relatadas dificuldades inerentes ao

processo de reconhecimento como a escolha adequada dos sensores e do conjunto de atividades a serem classificadas.

O sistema proposto consistiu em realizar o reconhecimento de 6 atividades humanas básicas utilizando RNAs com dados de sensores disponíveis em um banco de dados público criado por Anguita *et al* (2013).

Os bons resultados apresentados pelo sistema de RAH mostram a grande aplicabilidade das redes neurais auto-associativas para problemas de classificação, mostrando assim sua eficiência não só para problemas de compressão de sinais (onde estas redes vêm sendo mais utilizadas) mas também para problemas onde se possa utilizar a capacidade de mapeamento de identidade da RNA para lidar inclusive com sinais brutos.

O principal trabalho gerado a partir dos estudos e resultados aqui obtidos, intitulado "Reconhecimento de Atividades Humanas utilizando Redes Neurais Auto-associativas e dados de um *Smartphone*" foi publicado nos anais do XIII Encontro Nacional de Inteligência Artificial e Computacional e pode ser encontrado em www.lbd.dcc.ufmg.br/colecoes/eniac/2016/032.pdf ou ainda em www.lbd.dcc.ufmg.br/bdbcomp/servlet/Trabalho?id=24434.

Como futuros trabalhos propõe-se utilizar a mesma técnica para reconhecimento de outras atividades humanas, melhorar a taxa de acerto de forma global, trabalhar com os dados obtidos também no domínio da frequência e com os outros subconjuntos de dados que estão disponíveis na base. Além disso, também é possível a utilização de diversos banco de dados, afim de se comparar diferentes cenários com múltiplas atividades. Ademais, ainda é possível a criação de um sistema embarcado com sensores vestíveis para RAH utilizando o classificador gerado pela metodologia aqui proposta.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ABBATE, S.; AVVENUTI, M.; CORSINI, P. **Monitoring of human movements for fall detection and activities recognition in elderly care using wireless sensor network: a survey**. *Wireless Sensor Networks ApplicationCentric Design*, p. 1–20, 2010.

AGGARWAL, J.; RYOO, M. **Human activity analysis: A review**. *ACM Computing Surveys (CSUR)*, v. 43, n. 3, p. 16:1-16:43, 2011.

AGUIAR, B. et al. **Accelerometer-based fall detection for smartphones**. *IEEE MeMeA 2014 - IEEE International Symposium on Medical Measurements and Applications, Proceedings*, 2014.

ÁLVAREZ DE LA CONCEPCIÓN, M. Á. et al. **Mobile activity recognition and fall detection system for elderly people using Ameva algorithm**. *Pervasive and Mobile Computing*, 2016.

ANGUITA, D. et al. **A Public Domain Dataset for Human Activity Recognition Using Smartphones**. *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, n. April, p. 24–26, 2013.

ANJUM, A.; ILYAS, M. U. **Activity recognition using smartphone sensors**. *IEEE 10th Consumer Communications and Networking Conference, CCNC 2013*, p. 914–919, 2013.

AVCI, A. et al. **Activity Recognition Using Inertial Sensing for Healthcare, Wellbeing and Sports Applications: A Survey**. *Architecture of computing systems (ARCS), 2010 23rd international conference on*, p. 1–10, 2010.

BALDI, P. **Autoencoders, Unsupervised Learning, and Deep Architectures**. *ICML Unsupervised and Transfer Learning*, p. 37–50, 2012.

BAO, L.; INTILLE, S. S. **Activity Recognition from User-Annotated Acceleration Data**. *Pervasive Computing*, p. 1–17, 2004.

BASCOL, K. et al. **Unsupervised Interpretable Pattern Discovery in Time Series Using Autoencoders**, 2016.

BAYAR, V.; YAYAN, U.; YAZICI, A. **Detection of the smart phone position on user using inertial sensors**. *24th Signal Processing and Communication Application Conference (SIU)*, p. 933–936, 2016.

BAYAT, A.; POMPLUN, M.; TRAN, D. A. **A study on human activity recognition using accelerometer data from smartphones**. *Procedia Computer Science*, v. 34, n. C, p. 450–457, 2014.

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. **Neural Network Toolbox™ User's Guide**, 2015.

BERCHTOLD, M. et al. **An extensible modular recognition concept that makes activity recognition practical**. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 6359 LNAI, p. 400–409, 2010.

BERNARDA, L. T.; DE CARVALHO, A. P.; ANTONIO, B. **Redes Neurais Artificiais: Teoria E Aplicações**, 2000.

BIN ABDULLAH, M. F. A. et al. **Classification algorithms in human activity recognition using smartphones**. *International Journal of Medical, Health, Biomedical, Bioengineering and Pharmaceutical Engineering*, v. 6, n. 8, p. 362–369, 2012.

BOLZANI, C. A. M. **Residências inteligentes**. [s.l.] Editora Livraria da Física, 2004.

BULLING, A.; BLANKE, U.; SCHIELE, B. **A tutorial on human activity recognition using body-worn inertial sensors**. *ACM Computing Surveys*, v. 46, n. X, p. 1–

33, 2014.

CASALE, P.; PUJOL, O.; RADEVA, P. **Personalization and user verification in wearable systems using biometric walking patterns**. *Personal and Ubiquitous Computing*, v. 16, n. 5, p. 563–580, 2012.

CHAKROBORTY, S. **Accurate Arrhythmia classification using auto-associative neural network**. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, v. 91, n. 0, p. 4247–4250, 2013.

CHAMBERS, G. **Hierarchical recognition of intentional human gestures for sports video annotation**. *Pattern Recognition, ...*, v. 0, n. c, p. 3–6, 2002.

CHAUDHARY, S. et al. **Bus boarding event detection using smartphone sensors**. *8th International Conference on Communication Systems and Networks, COMSNETS 2016*, p. 1–6, 2016.

CHEN, L. et al. **Activity Recognition in Pervasive Intelligent Environments**. [s.l.: s.n.], 2011.

CHEN, L. et al. **Sensor-based activity recognition**. *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, v. 42, n. 6, p. 790–808, 2012.

CHETTY, G.; WHITE, M. **Body sensor networks for human activity recognition**. *3rd International Conference on Signal Processing and Integrated Networks (SPIN)*, p. 660–665, 2016.

ERMES, M. et al. **Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions**. *IEEE Transactions on Information Technology in Biomedicine*, v. 12, n. 1, p. 20–26, 2008.

FACELI, K.; LORENA, G. J. DE C. A. C. P. L. F. **Inteligência Artificial: Uma abordagem de Aprendizagem de Máquina**. [s.l.] Rio de Janeiro, LTC., 2011.

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

FAYYAD, U. M. et al. **Advances in knowledge discovery and data mining**. [s.l.] AAAI press Menlo Park, 1996. v. 21

FIGO, D. et al. **Preprocessing techniques for context recognition from accelerometer data**. *Personal and Ubiquitous Computing*, v. 14, n. 7, p. 645–662, 2010.

FIGUEIREDO, L. et al. **Aplicações de acelerômetros**. Monografia. Lisboa, Portugal, p. 1–12, 2007.

FORHAN, N. A. E. **Giroscópios MEMS**. Ministério da Ciência e Tecnologia. Instituto Nacional de Pesquisas Espaciais, p. 82, 2010.

FRANK, K. et al. **Bayesian recognition of motion related activities with inertial sensors**. *Proceedings of the 12th ACM international conference adjunct papers on Ubiquitous computing - Ubicomp '10*, n. January 2016, p. 445, 2010.

FU, Y. **Human Activity Recognition and Prediction**. Springer: [s.n.], 2016.

GANDETTO, M. et al. **From multi-sensor surveillance towards smart interactive spaces**. *Proceedings - IEEE International Conference on Multimedia and Expo*, v. 1, p. I641–I644, 2003.

GHOSH, A.; RICCARDI, G. **Recognizing Human Activities from Smartphone Sensor Signals**. *ACM International Conference on Multimedia*, p. 865–868, 2014.

GUIRY, J. J.; VAN DE VEN, P.; NELSON, J. **Classification techniques for smartphone based activity detection**. *Cybernetic Intelligent Systems (CIS), 2012 IEEE 11th International Conference on*, p. 154–158, 2012.

GUO, D. F. et al. **Human Activity Recognition using Smartphone Sensors with Context Filtering**. *ACHI 2016: The Ninth International Conference on Advances in Computer-Human Interactions Human*, v. 571–572, n. c, p. 1019–1029, 2016.

HAMMERLA, N. Y.; HALLORAN, S.; PLOETZ, T. **Deep, Convolutional, and**

Recurrent Models for Human Activity Recognition using Wearables. arXiv preprint arXiv:1604.08880, 2016.

HAYKIN, S. S. et al. **Neural networks and learning machines.** [s.l.] Pearson Upper Saddle River, NJ, USA:, 2009. v. 3

ITU. **ICT Facts and figures 2016.** p. 8, 2016.

IVERSEN, A.; TAYLOR, N. K.; BROWN, K. E. **Classification and verification through the combination of the multi-layer perceptron and auto-association neural networks.** Proceedings of the International Joint Conference on Neural Networks, v. 2, n. July 2016, p. 1166–1171, 2005.

IVERSEN, A.; TAYLOR, N. K.; BROWN, K. E. **Classification of Communication Signals and Detection of Unknown Formats Using Artificial Neural Networks.** Military Communications, v. RTO-MP-IST, n. July 2016, 2006.

JIANG, W. **Human Activity Recognition using Wearable Sensors by Deep Convolutional Neural Networks.** Proceedings of the 23rd ACM international conference on Multimedia., p. 1307–1310, 2015.

KANGAS, M. **Development of accelerometry-based fall detection – from laboratory environment to real- life.** [s.l: s.n.], 2011.

KASTNER, M.; STRICKERT, M.; VILLMANN, T. **A sparse kernelized matrix learning vector quantization model for human activity recognition.** European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN), n. April, p. 24–26, 2013.

KATZ, S. et al. **Progress in development of the index of ADL.** The gerontologist, v. 10, n. 1 Part 1, p. 20–30, 1970.

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

KOSE, M.; INCEL, O. D.; ERSOY, C. **Online Human Activity Recognition on Smart Phones.** In: 2nd International Workshop on Mobile Sensing: From Smartphones and Wearables to Big Data, p. 11–15, 2012.

KRAMER, M. A. **Nonlinear principal component analysis using autoassociative neural networks.** AIChE journal, v. 37, n. 2, p. 233–243, 1991.

KWAPISZ, J. R.; WEISS, G. M.; MOORE, S. A. **Activity recognition using cell phone accelerometers.** ACM SIGKDD Explorations Newsletter, v. 12, p. 74, 2011.

LABRADOR, M. A.; YEJAS, O. D. L. **Human Activity Recongnition: Using Wearable Sensors and Smartphones.** CRC Press: [s.n.], 2013.

LANE, N. et al. **BeWell: A Smartphone Application to Monitor, Model and Promote Wellbeing.** Proceedings of the 5th International ICST Conference on Pervasive Computing Technologies for Healthcare, p. 8, 2011.

LANE, N.; MILUZZO, E.; LU, H. **A Survey of Mobile Phone Sensing.** Ieee Communications Magazine, v. 48, n. 9, p. 140–150, 2010.

LARA, Ó. D. et al. **Centinela: A human activity recognition system based on acceleration and vital sign data.** Pervasive and Mobile Computing, v. 8, n. 5, p. 717–729, 2012.

LARA, O. D.; LABRADOR, M. A. **A Survey on Human Activity Recognition using Wearable Sensors.** IEEE Communications Surveys & Tutorials, v. 15, n. 3, p. 1192–1209, 2013.

LE, T. D.; NGUYEN, C. VAN. **Human Activity Recognition by smartphone.** IEEE National foundation for science and technology development conference on information and computer science, n. November, p. 219–224, 2015.

LEE, J. B. et al. **Decision-tree-based human activity classification algorithm using**

single-channel foot-mounted gyroscope. *Electronics Letters*, v. 51, n. 9, p. 675–676, 2015.

LI, Q. et al. **Accurate, Fast Fall Detection Using Posture and Context Information.** *Sensys'08: Proceedings of the 6th Acm Conference on Embedded Networked Sensor Systems*, p. 443–444, 2008.

LONG, X. L. X.; YIN, B. Y. BIN; AARTS, R. M. **Single-accelerometer-based daily physical activity classification.** *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, p. 6107–6110, 2009.

LUŠTREK, M.; KALUŽA, B. **Fall Detection and Activity Recognition with Machine Learning.** v. 33, p. 205–212, 2008.

MARTÍN, H. et al. **Activity logging using lightweight classification techniques in mobile devices.** *Personal and Ubiquitous Computing*, v. 17, n. 4, p. 675–695, 2013.

MAURER, U. et al. **Activity recognition and monitoring using multiple sensors on different body positions.** *Proceedings - BSN 2006: International Workshop on Wearable and Implantable Body Sensor Networks*, v. 2006, n. October, p. 113–116, 2006.

MEDRANO, C. et al. **Detecting falls as novelties in acceleration patterns acquired with smartphones.** *PLoS ONE*, v. 9, n. 4, 2014.

MIRANDA, V.; CASTRO, A. R. G.; LIMA, S. **Transformer fault diagnosis based on autoassociative neural networks.** *Intelligent System Application to Power Systems (ISAP), 2011 16th International Conference on*, IEEE, p. 1–5, 2011.

MIRANDA, V.; CASTRO, A. R. G.; LIMA, S. **Diagnosing faults in power transformers with autoassociative neural networks and mean shift.** *IEEE Transactions on Power Delivery*, v. 27, n. 3, p. 1350–1357, 2012.

NIKE. **Nike+.** Disponível em: <<http://www.nikeplus.com.br/>>. Acesso em: 15 out. 2016.

NOURY, N. et al. **Fall detection - Principles and Methods.** *29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, p. 1663–1666, 2007.

ONIGA, S.; SUTO, J. **Human activity recognition using neural networks.** *Proceedings of the 2014 15th International Carpathian Control Conference (ICCC)*, p. 403–406, 2014.

ORTIZ, J.-L. et al. **Transition-Aware Human Activity Recognition using smartphones.** *Neurocomputing: An International Journal*, v. 171, p. 754–767, 2016.

ORTIZ, J. L. R. **Smartphone- Based Human Activity Recognition.** Springer: [s.n.].2015

ORTIZ, J.; ONETO, L.; SAM, A. **Transition-Aware Human Activity Recognition Using Smartphones.** *Neurocomputing*, 171, 754-767, 2016.

PATSKO, L. **Tutorial–Aplicações, Funcionamento e Utilização de Sensores.** Maxwell Bohr: Instrumentação eletrônica, p. 84, 2006.

QUINLAN, J. R. **Induction of decision trees.** *Machine learning*, v. 1, n. 1, p. 81–106, 1986.

QUINLAN, J. R. **C4. 5: Programming for machine learning.** Morgan Kauffmann, p. 38, 1993.

RASEKH, A; CHEN, C.; LU, Y. **Human activity recognition using smartphone.** *Fall CSCE666 Project Report*, p. 2012–2015, 2011.

RAVI, N. et al. **Activity Recognition from Accelerometer Data.** *Proceedings of the national ...*, p. 1541–1546, 2005.

REISS, A.; HENDEBY, G.; STRICKER, D. **A Competitive Approach for Human Activity Recognition on Smartphones.** n. April, p. 24–26, 2013.

ROMERA-PAREDES; AUNG, M. S. .; BIANCHI-BERTHOUSSE, N. **A One-vs-One Classifier Ensemble with Majority Voting for Activity Recognition.** *ESANN 2013*, n.

April, p. 24–26, 2013.

SAFI, K. et al. **Physical activity recognition using inertial wearable sensors; A review of supervised classification algorithms**. International Conference on Advances in Biomedical Engineering (ICABME), p. 313–316, 2015.

SAFONOV, I. et al. **An approach for model assessment for activity recognition**. Pattern Recognition and Image Analysis, v. 25, n. 2, p. 263–269, 2015.

SAN-SEGUNDO, R. et al. **Feature extraction from smartphone inertial signals for human activity segmentation**. Signal Processing, v. 120, p. 359–372, 2016.

SEFEN, B. et al. **Human Activity Recognition Using Sensor Data of Smartphones and Smartwatches**. Proceedings of the 8th International Conference on Agents and Artificial Intelligence. International Conference on Agents and Artificial Intelligence. International Conference on Agents and Artificial Intelligence (ICAART-16), February 26-28, Rome, Italy, v. 2, n. Section 3, p. 488–493, 2016.

SHOAIB, M. et al. **Fusion of smartphone motion sensors for physical activity recognition**. [s.l: s.n.]. v. 14, 2015.

SHOAIB, M. et al. **A Survey of Online Activity Recognition Using Mobile Phones**. Sensors, v. 15, n. 1, p. 2059–2085, 2015.

SHOAIB, M. et al. **Complex human activity recognition using smartphone and wrist-worn motion sensors**. Sensors (Switzerland), v. 16, n. 4, p. 1–24, 2016.

SILVA C., J. R. C. **Smartphone Based Human Activity Prediction**. Master in Bioengineering. Universidade do Porto. Faculdade de Engenharia., p. 147, 2013.

SILVA G., F. G. DA. **Reconhecimento de movimentos humanos utilizando um acelerômetro e inteligência computacional**. Tese de Doutorado. Universidade de São Paulo., 2013.

SINGH, R.; GARG, D. **Hybrid Machine Learning Algorithm for Human Activity Recognition Using Decision Tree and Particle Swarm Optimization**. International Journal of Engineering Science and Computing, v. 6, n. 7, p. 8379–8389, 2016.

STEWART, V. et al. **Practical automated activity recognition using standard smartphones**. IEEE International Conference on Pervasive Computing and Communications Workshops, PERCOM Workshops 2012, n. March, p. 229–234, 2012.

TAKAČ, B. et al. **Position and orientation tracking in a ubiquitous monitoring system for Parkinson disease patients with freezing of gait symptom**. Journal of Medical Internet Research, v. 15, n. 7, 2013.

TAPIA, E. M. et al. **Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart rate monitor**. Proceedings - International Symposium on Wearable Computers, ISWC, p. 37–40, 2007.

UDDIN, M. et al. **Wearable sensing framework for human activity monitoring**. Proceedings of the 2015 workshop on Wearable Systems and Applications, Acm, 2015.

USTEV, Y.; INCEL, O. D.; ERSOY, C. **User, device and orientation independent human activity recognition on mobile phones: challenges and a proposal**. ACM conference on, p. 1427–1435, 2013.

VAVOULAS, G. et al. **The MobiFall dataset: An initial evaluation of fall detection algorithms using smartphones**. 13th IEEE International Conference on BioInformatics and BioEngineering, n. November, p. 1–4, 2013.

VEGA, J. **Monitoring Parkinson's Disease Progression Using Behavioural Inferences, Mobile Devices and Web Technologies**. Proceedings of the 25th International Conference Companion on World Wide Web, p. 323–327, 2016.

WANG, L. **Recognition of human activities using continuous autoencoders with wearable sensors**. Sensors (Switzerland), v. 16, n. 2, 2016.

WOODMAN, O. **An introduction to inertial navigation**. University of Cambridge,

Computer Laboratory, Tech. Rep. UCAMCL-TR-696, 14, 15., v. 67, n. 3B, p. 961–2, 2009.

WORLD HEALTH ORGANIZATION et al. **The world report on ageing and health.** Gerontologist, v. 56, p. S163–S166, 2016.

YAN, Z.; ABERER, K. **Energy-efficient Continuous Activity Recognition on Mobile Phones : An Activity-adaptive Approach,** 2012.

ZHANG, Q. et al. **A Fall Detection Study Based on Neural Network Algorithm Using AHRS.** In Information and Automation (ICIA), 2013 IEEE International Conference on (pp. 773-779). IEEE, n. August, 2013.

ZHANG, T. et al. **Fall Detection by Embedding an Accelerometer in Cellphone.** Journal of Computer Science, v. 6, n. 10, p. 277–284, 2006.