

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
INFORMÁTICA INDUSTRIAL – CPGEI

LUIZ CARLOS GIACOMOSI

**MÉTODO NÃO INVASIVO UTILIZANDO ACELERÔMETRO PARA CLASSIFICAR
MOVIMENTOS NORMAIS E ANORMAIS DE HUMANOS**

DISSERTAÇÃO

CURITIBA
2011

LUIZ CARLOS GIACOMOSSI

**MÉTODO NÃO INVASIVO UTILIZANDO ACELERÔMETRO PARA CLASSIFICAR
MOVIMENTOS NORMAIS E ANORMAIS DE HUMANOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná, como requisito parcial para a obtenção do grau de mestre em Ciências – Área de Concentração: Engenharia Biomédica.

Orientador: Prof. Dr. Sérgio Francisco Pichorim

CURITIBA
2011

Dados Internacionais de Catalogação na Publicação

G426 Giacomossi, Luiz Carlos

Método não invasivo utilizando acelerômetro para classificar movimentos normais e anormais de humanos / Luiz Carlos Giacomossi — 2011.

96 f. : il. ; 30 cm

Orientador: Sérgio Francisco Pichorim.

Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. Curitiba, 2011.

Bibliografia: f. 89-94.

1. Acelerômetros. 2. Mecânica humana – Classificação. 3. Redes neurais. 4. Reconhecimento de padrões. 5. Detectores. 6. Engenharia elétrica – Dissertações. I. Pichorim, Sérgio Francisco, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD (22. ed.) 621.3

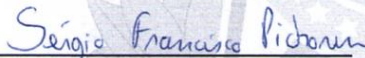
Título da Dissertação Nº 562:

**“Método Não Invasivo Utilizando Acelerômetro para
Classificar Movimentos Normais e Anormais de
Humanos”**

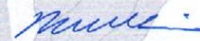
por

Luiz Carlos Giacomossi

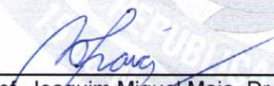
Esta dissertação foi apresentada como requisito parcial à obtenção do grau de MESTRE EM CIÊNCIAS – Área de Concentração: Engenharia Biomédica, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI – da Universidade Tecnológica Federal do Paraná – UTFPR – Campus Curitiba, às 14h do dia 07 de junho de 2011. O trabalho foi aprovado pela Banca Examinadora, composta pelos professores:




Prof. Sérgio Francisco Pichorim, Dr.
(Presidente – UTFPR)



Prof. Roberto Tadeu Raitz, Dr.
(UFPR)



Prof. Joaquim Miguel Maia, Dr.
(UTFPR)



Prof.ª Leyza Baldo Dorini, Dr.
(UTFPR)

Visto da coordenação:



Prof. Fábio Kurt Schneider, Dr.
(Coordenador do CPGEI)

Dedico esta dissertação primeiramente a Deus, pois sem Ele nada seria possível.

À minha família pelo incentivo e confiança demonstrada.

À minha esposa e filhos, pelo apoio incondicional, compreensão e motivação.

Ao meu orientador pela disposição em ensinar e paciência dedicada no decorrer do trabalho.

Enfim, a todos que de alguma forma tornaram este caminho mais fácil de ser percorrido.

AGRADECIMENTOS

Agradeço a Deus que me deu coragem de superar todos os desafios e escolhas que fiz em minha vida.

Aos meus pais Dagmar Giacomossi e Osvaldo Giacomossi (in memoriam) pelo incentivo aos estudos e pelo exemplo de vida.

À minha esposa Alessandra B. Giacomossi e aos meus filhos Luiz Carlos Giacomossi Jr e Eduardo Giacomossi pela paciência, colaboração, incentivo e amor.

Ao Professor Dr. Sergio Francisco Pichorim, pela oportunidade, orientação, dedicação e confiança em mim depositada.

Ao Dr. Alfredo Lohr Jr, pela orientação, apoio e préstimos.

Ao Prof. Dr. Roberto Tadeu Raittz, pela orientação, apoio e préstimos.

Aos colegas do CPGEI Gustavo Theodoro Laskoski, André Pepino, Carmen Caroline Rasera e Terezinha Strapasson pelas contribuições e companheirismo.

Aos alunos de iniciação científica Vitor Hirozawa, Luiz Davi Leite Martins, Alexandre Vassinievski e Felipe da Silva Ribeiro pela participação no desenvolvimento do projeto, companheirismo, estímulo e partilha.

Aos professores pelo conhecimento compartilhado.

Ao Instituto Federal do Paraná na pessoa do Diretor do Campus Curitiba Luiz Gonzaga Alves de Araujo, pela compreensão, estímulo e companheirismo.

Aos colegas de colegiado do IFPR pela dispensa para a conclusão do trabalho de pesquisa.

RESUMO

GIACOMOSSI, Luiz Carlos. Método não invasivo utilizando acelerômetro para classificar movimentos normais e anormais de humanos. 2011. 96 f. Dissertação (Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná). Curitiba, 2011.

O objetivo desta pesquisa é a captura e classificação de movimentos humanos anormais (tremores, vibrações, espasmos e contrações musculares) e movimentos normais do cotidiano. Pretende-se fornecer alguns resultados para demonstrar a eficiência da utilização do acelerômetro como elemento sensor de movimentos em aplicações médicas. Um dispositivo módulo sensor, não invasivo, desenvolvido pelos alunos de iniciação científica do CPGEI-UTFPR, baseado no componente integrado eletrônico acelerômetro, foi colocado no pulso de voluntários para a captura dos movimentos objetos de estudo. Todos os experimentos foram realizados no laboratório Biota da UTFPR. Os movimentos andando, correndo, aceno de tchau, batendo palmas e tremores foram capturados de 5 voluntários adultos. Um pré-processamento *off-line* é efetuado por um programa desenvolvido na linguagem Matlab 6.5, o qual extrai as principais características que devem refletir a amplitude, intensidade e frequência de cada movimento e fornecer um arquivo contendo os padrões supervisionados. Utilizou-se uma rede neural *fuzzy* do tipo *Free Associative Neuron* (FAN) e uma rede neural *Multi-Layer Perceptron* (MLP) para classificar um banco de dados contendo um total de 375 padrões, dos quais 250 (50 de cada movimento) são utilizados para a fase de treinamento e 125 (25 de cada movimento) para a fase de validação dos dados. Os percentuais de acerto médio obtidos na classificação dos dados capturados de 5 indivíduos foram de 81,6% para a rede neural FAN e 72,6% para a rede MLP. Outro experimento foi realizado para capturar os mesmos movimentos do estudo anterior provenientes de um único indivíduo. De um total de 2100 padrões, 1500 foram utilizados para treinamento (300 de cada movimento) e 600 (120 de cada movimento) para a validação dos dados. Os percentuais de acerto médio na classificação dos dados foram de 98,2% para a rede neural FAN e 96,7% para a rede neural MLP, observando-se uma melhora significativa nos resultados. Um último experimento foi realizado acrescentando ao banco de dados mais alguns movimentos executados por um único indivíduo: penteando, aparafusando, círculos, socos no ar e coçando a perna. Os percentuais de acerto médio obtidos na classificação dos dados foram de 99,3% para a rede neural FAN e 99,1% para a rede neural MLP. Os resultados da classificação dos dados para um total de 10 movimentos e padrões elaborados com 13 características foram obtidos baseando-se em um banco de dados contendo um total de 4200 padrões, dos quais 3000 (300 de cada movimento) são dedicados para a fase de treinamento e 1200 (120 de cada movimento) para a fase de validação dos dados. Neste experimento houve uma melhora ainda mais significativa na classificação dos dados, tendo em vista o acréscimo de 3 novas características aos padrões de treinamento: valores posturais (*offset*) extraídos dos sinais referentes aos eixos x, y e z do acelerômetro.

Palavras-Chave: Movimentos corporais normais e anormais. Método não invasivo. Acelerômetros. Redes neurais *fuzzy* e MLP. Detecção e classificação.

ABSTRACT

GIACOMOSSI, Luiz Carlos. Noninvasive method using accelerometer for classifying normal and abnormal movements of human. 2011. 96 f. Dissertation (Post-Graduate Program in Electrical Engineering and Computer Science Industrial of the Federal Technological University of Parana). Curitiba, 2011.

The aim of this research is the capture, detection and classification of abnormal human movements (tremors, vibrations, spasms and muscle contractions) and normal movements of everyday life. It is intended to provide some results to demonstrate the efficiency of use accelerometer as sensor of motion for medical applications. A device sensor module, non-invasive device, developed by undergraduate students of UTFPR, based on integrated electronic accelerometer, was placed on the wrist of volunteers to capture the movements. All experiments were performed in the laboratory Biota of CPGEI-UTFPR. The movement of walking, running, waving a goodbye, clapping and shaking, were captured in 5 adult volunteers. A pre-processing was done off-line by a program developed using Matlab 6.5, which extracts key features that should reflect the breadth, intensity and frequency of each movement and provide a file containing the standard supervised. We used a fuzzy neural network-type Free Associative Neuron (FAN) and a neural network Multi-Layer Perceptron (MLP) to classify a database containing a total of 375 patterns, of which 250 (50 of each movement) are used for the training phase and 125 (25 of each movement) to data validation. The average percentage of correct classification of data obtained from 5 individuals, were captured from 81.6% for the neural network FAN and 72.6% for MLP. Another experiment was conducted to capture the same movements in the previous study from a single individual. From a total of 2100 patterns, 1500 were used for training (300 for each movement) and 600 (120 for each movement) for validation. The average percentage of correct classification of the data were 98.2% for the neural network FAN, 96.7% for MLP neural network, observing a significant improvement in the results. A final experiment was performed adding to the database some more movements performed by a single individual: combing, bolting, circles, punching the air and scratching his leg. The average percentage of correct classification of the data obtained were 99.3% for the neural network FAN and 99.1% for MLP neural network. The results of the classification of data for a total of 10 movements and elaborate patterns with 13 features were obtained based on a database containing a total of 4200 patterns, of which 3000 (300 for each movement) are dedicated for the training and 1200 (120 for each movement) to data validation. In this experiment there was a further improvement in data classification, considering the addition of three new features to the training patterns, postural values (offset) extracted from the signals related to the axes x, y and z of the accelerometer.

Keywords: Normal and abnormal body movements. Noninvasive method. Accelerometers. Fuzzy neural network and MLP. Detection and classification.

LISTA DE FIGURAS

Figura 1 - Em (a) e (b) os gráficos apresentam a energia de captura dos.....33 acelerômetros colocados no braço esquerdo e perna esquerda.....33 respectivamente, com o “limiar” calculado representado na horizontal...33 e diferenciado para ambos.....33	33
Figura 2 - O gráfico mostra a necessidade de duas condições para o.....34 acionamento do alarme. A amplitude do movimento deve ultrapassar...34 $G_{\text{mín}}=90$ (primeira condição) durante um tempo mínimo ($T_{\text{mín}}=15$).....34 amostras consecutivas (segunda condição).....34	34
Figura 3 - O sensor de movimento é preso ao pulso de voluntários e os dados.....35 são armazenados em um computador para o processamento <i>off-line</i>35	35
Figura 4 - Diagrama em blocos de um alarme onde o sinal original é.....36 transformado em um novo sinal que sempre excede o original.....36	36
Figura 5 - Diagrama em blocos das fases de processamento dos sinais.....38 capturados por acelerômetros.....38	38
Figura 6 - Aquisição de dados de tremores com sensor acelerômetro colocado....40 no dedo da mão. A placa de circuito impresso de base estabelece a....40 comunicação com o computador para o armazenamento e.....40 processamento dos dados.....40	40
Figura 7 - Os dois blocos “padrão” e “algoritmo” são procedimentos executados...41 em paralelo e comparados no final.....41	41
Figura 8 - Exemplos típicos de sinais capturados no braço com acelerômetro.....43 3-D. O gráfico (a) mostra os sinais de uma crise tônica. O gráfico (b)....43 mostra os sinais de uma crise tônico-clônica. O gráfico (c) mostra os...43 sinais de movimentos normais virando folhas. O gráfico (d) mostra os...43 sinais de movimentos normais batendo um objeto na mesa.....43	43
Figura 9 - Quadro de classificação estruturado como árvore binária. Acima do.....45 pontilhado corresponde aos movimentos de atividades (classes).....45 Abaixo do pontilhado corresponde às orientações posturais.....45 (sub-nível ou sub-classe).....45	45
Figura 10 - Modelo não-linear simplificado de um neurônio artificial.....47	47
Figura 11 - Rede alimentada adiante ou acíclica com uma única camada de.....48 neurônios (<i>feedforward</i>).....48	48
Figura 12 - Rede alimentada adiante com múltiplas camadas de neurônios.....48 (<i>feedforward</i>).....48	48
Figura 13 - Rede recorrente com camada única, laços de realimentação e49 neurônios ocultos.....49	49
Figura 14 - Rede de múltiplas camadas alimentada adiante (<i>feedforward</i>),.....50 ressaltando o único neurônio da camada de saída, com a ilustração....50 da aprendizagem por correção de erro.....50	50
Figura 15 - Gráfico que representa um conjunto difuso e clássico de crianças.....52	52
Figura 16 - Diagrama em blocos do procedimento utilizado para o.....55 reconhecimento de padrões.....55	55
Figura 17 - Os gráficos (a), (b), (c), (d) e (e) são exemplos de algumas janelas.....61 com 100 pontos discretizados no tempo, dos sinais correspondentes...61 aos movimentos “andando”, “correndo”, “tremores”,.....61 “batendo palmas” e “aceno de tchau”, respectivamente.....61	61

Figura 18 - Os gráficos (a), (b), (c), (d) e (e) são exemplos de algumas janelas.....	62
com 100 pontos discretizados no tempo, dos sinais correspondentes..	62
aos movimentos “penteando”, “aparafusando”, “círculos”,.....	62
“socos no ar” e “coçando a perna”, respectivamente.....	62
Figura 19 - Orientação de aquisição de dados pelo acelerômetro nos três eixos.....	63
ortogonais.....	63
Figura 20 - Dispositivos utilizados no primeiro experimento para a captura e	64
armazenamento dos dados nos três eixos ortogonais.....	64
Figura 21 - Em (a) mostra a caixa onde o módulo foi condicionado.....	66
(3,8 cm x 6 cm) presa a um dos pulsos de voluntários por uma.....	66
pulseira de relógio. Em (b) apresenta a placa do módulo sensor.....	66
(3cm x 3cm) contendo o acelerômetro (modelo MA7260QT da.....	66
Freescall) à direita e o microcontrolador (circuito integrado modelo.....	66
PIC 16F886) à esquerda e em (c) a tela principal do <i>software</i> para.....	66
captura dos dados que são armazenados no PC.....	66
Figura 22 - Em (a), apresenta o projeto simplificado do módulo sensor que foi.....	67
adaptado ao pulso de voluntários. Em (b), apresenta a aquisição de.....	67
dados com comunicação serial via cabo até o bloco de comunicação,..	67
que por sua vez, estabelece a comunicação com um computador,.....	67
também via cabo (de um lado no padrão RS232 e do outro padrão.....	67
USB), onde os dados são gravados para o processamento posterior....	67
(<i>off-line</i>).....	67
Figura 23 - Gráfico que apresenta a Transformada Rápida de Fourier (FFT) do.....	69
cálculo de um dos padrões para o movimento batendo palmas.....	69
Figura 24 - O gráfico (a) mostra o sinal capturado pelo acelerômetro do.....	72
movimento penteando com o valor de “limiar” calculado em.....	72
aproximadamente 0,52. No gráfico (b) são apresentados somente os...72	72
pontos acima do “limiar” baseado na janela anterior. O gráfico (c).....72	72
mostra os pontos de mínimo e de máximo (considerar para toda a.....72	72
janela) encontrados e as retas calculadas entre esses pontos,.....72	72
formando uma sequência de triângulos.....	72
Figura 25 - Mostra a variável k que é o contador do número de pontos.....	73
calculados de mínimo e máximo (sobre os pontos que ultrapassaram...73	73
o valor estipulado como “limiar”), m o total de pontos gerados, i o.....73	73
contador de triângulos e n o total de triângulos gerados. As retas de....73	73
“subida”, “descida” e “base” calculadas entre os pontos de mínimo.....73	73
e máximo, formando uma sequência de triângulos irregulares.....73	73
Figura 26 - Mostra as treze características que formam os padrões calculados.....	77
no desenvolvimento do método e a última coluna como sendo a.....77	77
“classe” a que pertence cada um dos padrões supervisionados.....77	77
Figura 27 - Matriz de confusão do processamento com a rede neural FAN dos.....	79
padrões extraídos no terceiro experimento com 10 características.....79	79
(sem as características posturais).....	79

LISTA DE GRÁFICOS

Gráfico 1 - Resultados obtidos no primeiro experimento, envolvendo 5.....	80
voluntários adultos e 5 movimentos diferentes.....	80
Gráfico 2 - Resultados obtidos no segundo experimento, envolvendo 1.....	81
voluntário adulto e 5 movimentos diferentes.....	81
Gráfico 3 - Resultados obtidos no terceiro experimento, envolvendo 1.....	82
voluntário adulto e 10 movimentos diferentes.....	82

LISTA DE TABELAS

Tabela 1 - Valores de “Limiar” Calculados para os 10 Movimentos Objetos de.....	70
Estudo.....	70
Tabela 2 - Classes Correspondentes aos 10 Movimentos Objetos de Estudo.....	76
Tabela 3 - N° de Neurônios Utilizados nas Camadas da Rede Neural MLP nos.....	76
3 experimentos.....	76
Tabela 4 - Resultados Obtidos na Classificação dos Movimentos Realizados.....	80
por 5 voluntários.....	80
Tabela 5 - Resultados Obtidos na Classificação de 5 Movimentos Realizados.....	81
por 1 voluntário.....	81
Tabela 6 - Resultados Obtidos na Classificação de 10 Movimentos Realizados.....	82
por 1 voluntário.....	82

LISTA DE ABREVIATURAS E SIGLAS

AR	Modelagem Auto-Regressiva
AT	Área do Triângulo
BAS	Reta de Base
CEOL	Complexos Espícula-Onda Lenta
CONEP	Comissão Nacional de Ética em Pesquisa
DP	Doença de Parkinson
DES	Reta de Descida
EAI	Epilepsia de Ausência da Infância
ECG	Eletrocardiograma
EEG	Eletroencefalograma
EMG	Eletromiograma
EOG	Eletrooculograma
FAN	<i>Free Associative Neuron</i>
FFT	Transformada Rápida de Fourier
IA	Inteligência Artificial
MLP	<i>Multi-Layer Perceptron</i>
MB	Média das Retas de Base
MD	Média das Rampas de Descida
MP	Média dos Perímetros dos Triângulos
MS	Média das Rampas de Subida
SA	Soma das Áreas dos Triângulos

SUMÁRIO

1 INTRODUÇÃO	13
1.1 MOTIVAÇÕES.....	13
1.2 JUSTIFICATIVA.....	14
1.3 OBJETIVOS.....	15
1.3.1 Objetivo Geral.....	15
1.3.2 Objetivos Específicos.....	16
1.4 Organização da Dissertação.....	17
2 TREMORES HUMANOS	18
2.1 Tremor de Repouso.....	19
2.2 Tremor de Ação.....	19
2.3 Tremor Fisiológico.....	20
2.4 Doença de Parkinson (DP).....	21
2.5 Tremor Essencial (TE).....	22
2.6 Síndromes do Cerebelo.....	23
2.7 Epilepsia.....	23
2.7.1 Crises Parciais.....	26
2.7.2 Crises Generalizadas.....	27
2.7.2.1 Crises de Ausência.....	28
2.7.2.2 Crises Tônico-Clônicas.....	30
2.8 Resumo.....	31
3 MÉTODOS UTILIZADOS NA CAPTURA, DETECÇÃO E CLASSIFICAÇÃO DE MOVIMENTOS EM SERES HUMANOS – ESTADO DA ARTE	32
3.1 Redes Neurais Artificiais (RNAs).....	45
3.1.1 Redes Neurais Fuzzy.....	52
3.1.2 Rede Neural <i>Free Associative Neurons</i> (FAN).....	53
3.2 Reconhecimento de Padrões (RP).....	54
4 MÉTODO DE DESENVOLVIMENTO DA PESQUISA	57
4.1 Método de captura dos dados.....	57
4.2 Dispositivos de aquisição dos dados.....	63
4.3 Método para obtenção das características.....	67
5 RESULTADOS	78
6 DISCUSSÕES E CONCLUSÕES	83
6.1 DISCUSSÕES.....	83
6.2 CONCLUSÕES.....	84
6.3 TRABALHOS FUTUROS.....	87
REFERÊNCIAS	89
APÊNDICES.....	95
APÊNDICE A - Diagrama Esquemático do Módulo Sensor.....	95
APÊNDICE B – Diagrama Esquemático do Módulo de Comunicação.....	96

1 INTRODUÇÃO

1.1 MOTIVAÇÕES

A engenharia biomédica é uma especialidade relativamente recente, destacando-se pela utilização da tecnologia aplicada às soluções médicas. Dentro deste contexto, uma das motivações para o desenvolvimento desta pesquisa foi a busca de inovações e melhorias destinadas às pessoas que sofrem com patologias relacionadas aos distúrbios dos movimentos, como os casos graves de epilepsias, tremores de Parkinson (DP), tremor essencial (TE) e outros (DEUSCHL, BAIN e BRIN, 1988). Outro aspecto importante foi à inclusão de movimentos relacionados com as atividades do cotidiano nos experimentos realizados nesta pesquisa. O principal estímulo foi o estudo de Khan *et al.* (2010), onde foram capturados dados com sensor acelerômetro e armazenados vários movimentos de atividades diárias de pacientes idosos em suas casas. As informações processadas foram utilizadas para avaliar a evolução clínica no tratamento dos pacientes.

Diante de uma realidade que passa pelo preconceito, exclusão social e em prol das pessoas que sofrem de distúrbios dos movimentos, houve o estímulo em buscar na literatura os melhores trabalhos relacionados com a detecção de crises epiléticas, tremores, controle de atividades diárias, entre outros. Os principais parâmetros de análise são extraídos de movimentos corporais (contrações musculares, vibrações, tremores) através de um método de aquisição não invasivo aliado aos recursos computacionais. Visando propor uma análise rápida e eficiente sobre um campo de pesquisa relativamente recente e comprovadamente promissor (ELEVANT, 1999; NIJSEN, 2008; CUPPENS *et al.*, 2009; KHAN *et al.*, 2010).

Para o caso específico da epilepsia, uma doença que sempre foi vista como uma maldição, um feitiço, uma possessão relacionada com espíritos malignos (MARINO JÚNIOR, 1983), este trabalho poderá contribuir em futuros estudos com a classificação de alguns tipos de epilepsia (nos casos em que ocorre contração muscular) (GIACOMOSSI e PICHORIM, 2010) e detecção remota de crises ou quedas (BURCHFIELD e VENDATESAN, 2007).

Numa análise mais abrangente, este é mais um estudo que visa contribuir para os questionamentos e consenso da sociedade sobre os transtornos de movimentos, muitos deles ainda confusos pela associação de anomalias de movimentos corporais. Além disso, alguns são inclusive desconhecidos por não pertencerem a algum tipo de classificação reconhecida cientificamente (DEUSCHL, BAIN e BRIN, 1988).

1.2 JUSTIFICATIVA

Com o desenvolvimento desta pesquisa, pretende-se fornecer alguns resultados para demonstrar a eficiência da utilização do acelerômetro como elemento sensor de posição, movimentos de vibrações, tremores e contrações musculares, bem como os movimentos relacionados com as atividades realizadas no cotidiano em aplicações médicas futuras. Trata-se de um dispositivo eletrônico integrado de pequenas dimensões e peso, com baixo consumo, de fácil instalação, não invasivo, discreto e de fácil adaptação em qualquer parte do corpo humano, deixando o usuário mais a vontade e evitando alguns desconfortos em aplicações que envolvem a captura de dados diários. As vantagens de um sistema com o uso do acelerômetro são evidentes, principalmente nas avaliações de atividades do cotidiano ou atividades físicas com idosos. Nestes casos, os dados são coletados fora do ambiente hospitalar, possibilitando a redução dos custos com internamento (KHAN *et al.*, 2010).

Como aplicação em ambiente hospitalar, os acelerômetros não substituem um eletroencefalograma (EEG), mas podem servir como dispositivos auxiliares na avaliação dos movimentos para alguns casos de epilepsia. Outros tipos de sensores se fazem necessários para avaliar uma crise de ausência, como exemplo (NIJSEN, 2008).

Outro aspecto importante a ser analisado é a importância do uso de recursos computacionais para auxílio à tomada de decisão em um diagnóstico médico. Os resultados podem ser fornecidos em tempo real ou *off-line*. No entanto, nos dois casos, pode reduzir significativamente o tempo de atendimento e iniciar

imediatamente um tratamento com pacientes doentes, como exemplo a tuberculose pulmonar (SANTOS *et al.*, 2003).

A detecção de uma crise de epilepsia em tempo real pode evitar complicações como fraturas, sangramentos e danos cerebrais com seqüelas motoras e sensitivas (ELEVANT, 1999; NIJSEN, 2008).

O sistema proposto pode ser adaptado na detecção de crises em locais remotos. Nestes casos, o ideal é que, no módulo de detecção, seja embarcado o *software* da rede neural já treinada. Este treinamento deve ser realizado com os movimentos do paciente a ser monitorado para aumentar a precisão no reconhecimento dos padrões (ELEVANT, 1999).

1.3 OBJETIVOS

1.3.1 Objetivo Geral

O objetivo geral desta pesquisa é o desenvolvimento de um método não invasivo para capturar e classificar movimentos anormais (tremores, vibrações e espasmos musculares) e movimentos normais do cotidiano ou atividades diárias relacionadas com humanos. Todos os dados foram capturados, no laboratório Biota/CPGEI da Universidade Tecnológica Federal do Paraná, dados de adultos voluntários foram utilizados para compor um banco de dados de padrões supervisionados extraídos dos movimentos objetos de estudo (procedimento *off-line*) e submetidos a uma classificação final utilizando-se dos recursos de redes neurais, devido à sua grande capacidade de aprendizado e generalização (HAYKIN, 2001; RAITTZ, 2002).

1.3.2 Objetivos Específicos

Os objetivos específicos são:

- Desenvolver um dispositivo de *hardware* ou módulo sensor baseado no componente integrado eletrônico acelerômetro. Tal dispositivo deve apresentar pequenas dimensões e peso, não oferecer qualquer tipo de risco aos voluntários como: choque elétrico, emissão de radiação, aquecimento excessivo ou emissão de ruídos sonoros;
- Estabelecer a comunicação do módulo sensor como um computador local, para o armazenamento dos dados capturados e análise posterior;
- Capturar dados de movimentos anormais e normais do cotidiano de voluntários adultos no laboratório Biota/CPGEI, elaborando um banco de dados para o processamento posterior (*off-line*);
- Desenvolver um algoritmo no MATLAB (linguagem de programação ou *software* interativo de alta performance) para um pré-processamento, onde as principais características serão extraídas dos movimentos objetos de estudo, gerando um arquivo texto ou matriz contendo os padrões supervisionados;
- Processar (*off-line*) o arquivo contendo os padrões supervisionados utilizando dois tipos de rede neural para obter a classificação final dos movimentos objetos de estudo. Uma rede do tipo *fuzzy* ou FAN (*Free Associative Neuron*) e outra conexionista MLP (*Multi-Layer Perceptron*) para a comparação dos resultados; e
- Comparar a performance entre estes dois tipos de rede neural na classificação dos movimentos.

1.4 Organização da Dissertação:

O capítulo 2 apresenta os principais conceitos sobre as patologias relacionadas com tremores em humanos, incluindo os tipos de epilepsias.

O capítulo 3 apresenta os principais métodos utilizados na captura, detecção e classificação de movimentos em seres humanos – estado da arte.

O capítulo 4 apresenta o desenvolvimento do método.

O capítulo 5 apresenta os resultados obtidos com os experimentos.

O capítulo 6 apresenta as discussões e conclusões obtidas nesta pesquisa e quais trabalhos futuros podem ser desenvolvidos.

2 TREMORES HUMANOS

O objetivo da inclusão de uma abordagem resumida sobre alguns transtornos de movimentos que podem manifestar-se em humanos é trazer alguns esclarecimentos sobre o assunto, que notoriamente causa discriminação e constrangimentos às pessoas portadores dessas doenças. Além disso, tem relevância para esta pesquisa, bem como em futuros estudos, tendo em vista que o sistema proposto pode ajustar-se a qualquer um destes distúrbios.

Os tremores humanos foram considerados neste estudo como uma única categoria ou classe de movimentos denominada “tremores”, correspondendo aos movimentos amplos de contrações musculares, espasmos e vibrações intensas simulados em experimentos realizados no laboratório Biota/UTFPR.

Tais sintomas são referenciados na literatura de longa data, como em algumas citações bíblicas onde alguns milagres apontam a cura de alguns movimentos involuntários, embora seja difícil de interpretar a sua natureza fisiológica ou histérica. O grande Galeno menciona apenas uma forma de paralisia incompleta dos membros inferiores, sem dar qualquer explicação para os movimentos anormais (BARBEAU, 1982).

Os principais critérios utilizados nas classificações apresentadas sobre tremores estão embasados na tradicional análise clínica (DEUSCHL, BAIN e BRIN, 1988).

Basicamente, os tremores são movimentos involuntários, em série, rítmicos e que resultam de contrações alternadas entre grupos musculares antagonistas. Os parâmetros a serem observados são: localização, velocidade, amplitude, ritmo, relação com repouso, movimento, fadiga, emoção, atenção, estado de consciência, etiologia e condição patológica básica (GALHARDO, 1987). Quanto à fenomenologia dos tremores podemos diferenciá-los classificando-os como: tremor de repouso e tremor de ação.

2.1 Tremor de Repouso

O tremor de repouso ocorre quando a parte do corpo a ser observada não se encontra sobre o efeito da gravidade, os músculos não estão contraídos e inexistem as intenções voluntárias dos movimentos. Para observá-lo, o indivíduo deve estar relaxado, sentado em uma cadeira, com os braços apoiados ou deitado (VIEIRA, 2005). Usualmente apresenta características de movimentos que oscilam realizando adução e abdução ou flexão e extensão (BORGES e FERRAZ, 2006). Este tipo de tremor aumenta de amplitude durante *stress* mental (DEUSCHL, BAIN e BRIN, 1988).

2.2 Tremor de Ação

Quando o tremor é produzido por contração muscular voluntária podemos associar estes movimentos involuntários aos tremores de ação. Este tremor pode ser dividido em tremor postural, isométrico e cinético, sendo que este último inclui o tremor de intenção (DEUSCHL, BAIN e BRIN, 1988). O tremor postural pressupõe a ativação voluntária ou intencional dos músculos necessários para a manutenção de uma posição ou postura específica. Para verificar a existência deste tipo de tremor, o teste mais comum é pedir para que a pessoa estenda os braços com a palma virada para baixo, procurando manter os dedos separados e depois solicitando para rodar as mãos 90° com os polegares para cima (VIEIRA, 2005; DEUSCHL, BAIN e BRIN, 1988).

Já o tremor cinético manifesta-se em qualquer ocorrência de um movimento que envolva uma contração muscular voluntária (DEUSCHL, BAIN e BRIN, 1988). Este tipo de tremor pode ocorrer quando o movimento é dirigido intencionalmente a um alvo (nestes casos é designado como tremor de intenção) e aumenta significativamente com a perseguição de uma meta ou objetivo (DEUSCHL, BAIN e BRIN, 1988). Está ausente nos estados de repouso, pode ser de média amplitude e apresentar ritmo regular. No entanto, diferentemente de um movimento ser

direcionado para um ponto fixo (alvo) (BAIN, 2002) o tremor cinético também é classificado como simples, ou seja, pode ser observado ao realizar o movimento de pronação/supinação ou flexão/extensão dos punhos (DEUSCHL, BAIN e BRIN, 1988). Nestes casos, uma pessoa doente não consegue beber um copo de água ou passar o conteúdo de um copo para outro copo sem derrubar (VIEIRA, 2005).

Por último, o tremor de ação também é denominado de tremor isométrico. Pode ser constatado ao se efetuar um movimento de contração muscular contra um objeto rígido estacionário (BAIN, 2002). Fica em evidência quando o doente aperta com muita força os dedos do observador ou flexiona o punho contra uma mesa (VIEIRA, 2005).

2.3 Tremor Fisiológico

O tremor fisiológico é um tremor considerado normal que ocorre na frequência de 8 a 13 Hz e pode estar associado às vibrações passivas dos tecidos, produzidas pelas atividades mecânicas das batidas do coração. Também ocorre em situações de medo e ansiedade, distúrbios metabólicos (hipertireoidismo e hipoglicemia como exemplo), exercícios físicos, abstinência ao álcool e uso de certas drogas (lítio, prednisona) (MATTOS, 1988).

Os principais critérios para avaliação do tremor fisiológico são: tremor bilateral das mãos e antebraços (sem tremor de repouso), ausência de outros sinais neurológicos (exceção do sinal de Froment¹) e tremor isolado da cabeça sem postura anormal da mesma (BORGES e FERRAZ, 2006).

Nas síndromes do tremor fisiológico, a amplitude do tremor é baixa, e a frequência é alta para as mãos e dedos, sendo mais baixo para articulação proximal. Fatores mecânicos e neurais causam este tremor (DEUSCHL, BAIN e BRIN, 1988), o qual é facilmente visível com efeito postural. Não apresenta evidência de doença neurológica subjacente, apresenta alta frequência e os sintomas são normalmente

¹ Sinal de Froment – A pessoa não consegue prender uma folha de papel com a ponta do polegar pressionando a ponta do dedo indicador.

reversíveis, desde que sua causa seja identificado e corrigido (DEUSCHL, BAIN e BRIN, 1988).

2.4 Doença de Parkinson (DP)

Apenas o tremor de repouso já é um diagnóstico positivo para a DP, mas podem existir outros tipos de tremores. Corresponde a uma doença neurológica progressiva idiopática (de causa desconhecida) que afeta igualmente homens e mulheres na maioria das vezes após os 50 anos (FERREIRA *et al.*, 2007). O mais comum é a combinação de tremor postural com cinético associado ao repouso (DEUSCHL, BAIN e BRIN, 1988). Durante um movimento voluntário desaparece, mas reaparece ao adotar uma postura (em repouso), após algum tempo de latência (VIEIRA, 2005). Os movimentos repetitivos e lentos (bradicinesia) de 4 a 7 Hz, envolvendo principalmente o polegar e os dois primeiros dedos, que ao realizar movimentos de pronação (rotação interna do antebraço) ou supinação do punho (rotação externa do antebraço, para fora ou lateral), configuram a clássica analogia do “contador de dinheiro” (GALHARDO, 1987). Pode-se também associar rigidez muscular, hipomimia facial (diminuição da expressão), depressão, alteração da qualidade da voz, do equilíbrio e da marcha relacionados ou não a outras manifestações músculo esqueléticas e neurológicas como fraqueza e encurtamento muscular, demência, depressão com tendência ao isolamento (FERREIRA *et al.*, 2007; MOREIRA e NETO, 2007).

Para as avaliações do grau de severidade da DP, uma classificação de acordo com a escala de graus de incapacidade de Hoehn e Yahr foi criada em 1967. Foram definidos cinco estágios da doença, sendo que os três primeiros apresentam sintomas leves e moderados enquanto os dois últimos apresentam comprometimentos agravados (MOREIRA e NETO, 2007). No estágio inicial, o paciente mantém completa funcionalidade, tremor e rigidez unilateral. No estágio intermediário ocorre acometimento bilateral, bradicinesia, rigidez e alterações posturais, enquanto no estágio tardio todos os sintomas são reforçados, com grande comprometimento para as principais funções executadas no cotidiano. Conforme

descrito por James Parkinson em 1817, os principais aspectos envolvidos são: a chamada “postura em flexão” que envolve a flexão da cabeça, tronco ligeiramente voltado para frente, semiflexão das articulações dos joelhos, quadris e cotovelos (FERREIRA *et al.*, 2007).

2.5 Tremor Essencial (TE)

Entre os transtornos de movimentos este é o mais comum, estando associado aos tremores de ação com efeito postural (MATTOS, 1998). Ocorrendo isoladamente não apresenta outras alterações neurológicas (VIEIRA, 2005; JANKOVIC, 2000).

As porções distais são as mais afetadas pelo tremor essencial, ou seja, envolve as extremidades e em termo de freqüência oscila entre 5 a 7 Hz. Freqüentemente apresenta-se como um tremor fino, amplo, rápido, segundo os critérios de freqüência e amplitude do mesmo, acometendo principalmente as mãos, os braços e também a cabeça (MATTOS, 1988). Em alguns pacientes pode comprometer as pernas, o queixo, a língua, os músculos laríngeos e os olhos (BARBEAU, 1982). Em qualquer fase da vida pode manifestar-se, sendo mais comum após os 40 anos e tende a uma acentuação com o aumento da idade (MATTOS, 1988). Muitos pacientes apresentam dificuldades para se pentear, falar em público ou tomar uma xícara de café.

Quando intencionalmente pretende-se reduzir o tremor, com a expectativa gerada e o aumento da concentração (tensão), normalmente nestas condições os sintomas tendem a piorar. Este tremor pode interferir na escrita e nos trabalhos manuais, bem como dificultar as relações sociais (BARBEAU, 1982). Embora possa produzir algumas alterações, o TE desaparece durante o repouso e aumenta ao manter uma postura com uma extremidade (tremor estático, postural ou de atitude). Geralmente é acentuado ao aproximar-se de um alvo (tremor terminal). Normalmente desaparece com o repouso completo ou ao andar com os braços soltos ao lado do tronco (BARBEAU, 1982).

O TE pode apresentar-se de forma severa e, nestes casos, os sintomas são todos reforçados principalmente em termos de amplitude. Como pode ocorrer em repouso, característica que geralmente está associado à doença de Parkinson, acaba sendo confundido, dificultando bastante o diagnóstico das patologias em questão. Não se sabe se os pacientes apresentam a doença de Parkinson associada ou mais tardiamente desenvolverão tais sintomas (MATTOS, 1998).

2.6 Síndromes do Cerebelo

Os tremores também podem estar associados com problemas no cerebelo e são mais freqüentes quando há a intenção de um movimento (sinônimo de tremor do cerebelo), podendo ser unilateral ou bilateral com freqüências inferiores a 5 Hz. Quando o paciente está em repouso é inexistente, podendo associar-se ao tremor postural (VIEIRA, 2005).

Basicamente relacionado com alterações do cerebelo e/ou suas vias, tem como entidades patológicas características a esclerose múltipla ou as degenerações do cerebelo (regiões medulares e tumores cerebelares). É evidenciado nas provas índice-nariz (GALHARDO, 1987).

2.7 Epilepsia

A palavra epilepsia deriva do grego *epilambarin* (*epi* + *lambarin* + *ia*), algo que ataca de surpresa ou assalta. A expressão “ataque epiléptico” está relacionada com algo que vem de fora ou ataca subitamente. Talvez a epilepsia seja um dos males mais antigos que aflige os seres humanos. Hipócrates nos deu uma grande contribuição, percebendo que a epilepsia tem como sede ou origem o cérebro, afirmando que as causas são naturais e não sobrenaturais. No entanto, muito tempo antes de Hipócrates (460 A.C.) já havia a consciência de que esta doença não

pertencia apenas aos Deuses e nem se tratava de uma maldição. O código de Hamurabi apresentava leis sobre o casamento de epiléticos, datando de 2080 A.C. (MARINO JUNIOR, 1983).

Com o avanço das ciências ao longo do tempo, muitos conhecimentos foram adquiridos sobre a anatomia e fisiologia do cérebro humano e sobre a epilepsia. Sabe-se que as camadas corticais e sub-corticais do encéfalo são formadas de uma substância cinzenta que abrange uma imensa rede neuronal, de onde partem os impulsos nervosos e os desígnios para as inúmeras funções realizados pelos humanos. Quando alguns neurônios defeituosos formam um foco em uma região de um dos hemisférios do cérebro, podendo ou não se estender para o hemisfério contra lateral, na maioria das vezes por motivos desconhecidos (idiopáticos), descargas elétricas anômalas e paroxísticas iniciam uma crise de epilepsia. As manifestações podem ser de caráter sensitivo ou sensorial, motor, autonômico, resultante do sistema nervoso autônomo pelo foco epileptogênico ou mental. A consciência é afetada em muitos casos, com amnésia anterógrada de duração variável (ANDRÉ, 1999).

As alterações cerebrais que ocorrem durante uma crise de epilepsia são temporárias e ao final a pessoa volta à condição normal. No entanto, é uma doença permanente e suas manifestações clínicas são intermitentes. Importante observar que as crises devem ser recorrentes e espontâneas para que uma pessoa seja considerada portadora de epilepsia. Uma única crise convulsiva isolada em um momento da vida, devido a uma febre alta, drogas ou distúrbios metabólicos, não é um indicativo de epilepsia (CAMBIER, MASSON e DEHEN 1999).

Uma síndrome epilética é uma composição de sinais e de sintomas que podem estar associados a determinadas patologias ou etiologias e são denominadas sintomáticas. Em outros casos, quando não existe uma causa etiológica conhecida ou patologia associada são identificadas como idiopáticas. Sendo assim, anormalidades de base ou cerebrais podem ser oriundas de diversas etiologias, incluindo a herança genética, os distúrbios do desenvolvimento, lesões ocorridas durante o parto (perinatal), o trauma, a infecção, o infarto ou a neoplasia (ROLAK, 1995).

Desde a mais tenra idade ou no período neonatal, estamos sujeitos a um problema bastante comum, as convulsões. Estas podem representar o primeiro ou único sinal de um distúrbio do sistema nervoso central. Alguns fatores podem ser

relevantes para o desenvolvimento de um quadro de epilepsia após o período neonatal, incluindo o coma e anormalidades severas do ritmo de base do eletroencefalograma (EEG) neonatal, a paralisia cerebral, o retardo mental e anormalidades claramente epileptiformes² no eletroencefalograma (MELO-SOUZA, 2000). Pacientes que sofrem de deficiência de desenvolvimento ou retardo mental comumente apresentam epilepsia e sofrem do chamado “duplo estigma” (com os dois sintomas simultâneos). O que agrava ainda mais a situação e o sofrimento que passam tais pacientes é a falta de capacitação e de conhecimento sobre a patologia em questão, tendo em vista a necessidade de tratamento específico para estes casos (NETO e MARCHETTI, 2005; PERSAD, 2003).

Também deve-se considerar que existem crises não-epilépticas psicogênicas definidas como episódios de alterações paroxísticas no comportamento, similares a crises epilépticas, porém não associadas a alterações quantificáveis da atividade elétrica cerebral (PORTUGUEZ *et al.*, 2007).

Em relação às convulsões em crianças, pelo menos 5 a 9% terão crises convulsivas ao longo da vida, sendo que 3% dos indivíduos apresentam crises recorrentes. A forma mais comum é a convulsão febril, em torno de 2 % apresentarão convulsões até 6 anos de idade (ANDRÉ, 1999). Existem também as epilepsias benignas da infância, com remissão espontânea das crises, sem déficit neurológico ou intelectual e com indicativos eletroencefalográficos focais (FONSECA e TEDRUS, 2000).

De acordo com a *International League Against Epilepsy* (ILAE) a primeira classificação foi publicada em 1960 e atualizada mais tarde em 1981 para os critérios de convulsões. Em 1989 foi apresentada a classificação internacional das epilepsias e síndromes epilépticas (CIESE) (MELO-SOUZA, 2000). Muitos são os fatores a serem observados para a definição dos critérios de epilepsia, como as características clínicas, os padrões eletroencefalográficos, herança familiar, a idade de início, recorrência das crises, entre outros. Diante da complexidade de análise, os critérios de classificação apresentados neste trabalho não devem ser vistos de forma rígida, considerando-se alguns aspectos já atualizados pela ILAE. No entanto, por

² Epileptiformes – são potenciais originados da excitação de neurônios corticais que compõem o foco epiléptico e destacam-se por ondas cerebrais que apresentam morfologia diferenciada da atividade normal cerebral (MARCHESI, 1998).

questões didáticas, optou-se pelo que foi estabelecido em 1981 (MELO-SOUZA, 2000; MARINO JUNIOR, 1983).

2.7.1 Crises Parciais

As crises parciais ou focais tem início em redes de neurônios limitadas a um hemisfério cerebral envolvendo as estruturas das camadas corticais e sub-corticais e não incluem o córtex inteiro necessariamente, podendo ser relativamente localizada, amplamente distribuída ou bilateral. Cada tipo de crise apresenta um início ictal³ consistente com padrões de propagação preferenciais, que pode ou não envolver o hemisfério contralateral. Em alguns casos são acometidas mais de uma rede epileptogênica, envolvendo mais de um tipo de crise. No entanto, todas apresentam como início um foco bem definido (ILAE, 2010).

As crises parciais simples apresentam manifestações conhecidas como auras. A aura é uma sensação anormal que antecede a uma crise (cheiros, luzes piscando, sintomas somato-sensitivos⁴, etc.). Quanto mais restrita a área envolvida, menores serão as manifestações e os sintomas da crise sem a perda de consciência (ROLAK, 1995). Uma epilepsia generalizada pode surgir difundindo-se às estruturas corticais e sub-corticais dos dois hemisférios cerebrais. Este fenômeno também é conhecido como generalização secundária (MARINO JUNIOR, 1983).

Por outro lado, as crises parciais complexas também podem ser precedidas por auras bem definidas e apresentam um tempo médio de crise de 90 segundos. Apresentam automatismo (seqüências comportamentais complexas realizadas inconscientemente), características autonômicas (dilatação da pupila e salivação) e perda da consciência para a crise. O paciente fica habitualmente confuso ou tem problemas cognitivos pós-ictal⁵. As crises parciais simples e complexas podem evoluir para generalizadas (ROLAK, 1995).

³ Período ictal - corresponde ao momento em que ocorre a crise (MARCHESI, 1998).

⁴ Somato-sensitivo – relativo às sensações do corpo.

⁵ Período pós-ictal corresponde ao momento pós-crise (MARCHESI, 1998).

As crises parciais complexas mais comuns entre os adultos são as epilepsias do lobo temporal. É normalmente intratável e não responde às drogas antiepilépticas disponíveis. Estes tipos de crises também podem surgir nos lobos frontais, parietais e occipitais (GARZON e SAKAMOTO, 2000). É caracterizada por crises parciais recorrentes, simples e complexas, e corresponde a cerca de 50% das epilepsias (UNIFESP, 2010).

No entanto, é preciso esclarecer que a clássica noção de epilepsia parcial (focal) e generalizada como completamente distintas não é totalmente verdadeira. Esta idéia está implícita pela ILAE. Não é incomum, na prática, que situações onde características clínicas e eletroencefalográficas de ambas se superponham. Tal situação ocorre principalmente nos casos de crises tônico-clônicas generalizadas, especialmente se estas ocorrem durante o sono ou correspondem a uma única manifestação clínica. Diante de pacientes com ausências, torna-se difícil a diferenciação entre epilepsia generalizada ou generalizada primária e secundária (MARINO JUNIOR, 1983).

2.7.2 Crises Generalizadas

As crises generalizadas originam-se de redes neuronais distribuídas bilateralmente. Essas redes podem incluir estruturas corticais e sub-corticais, mas não necessariamente o córtex inteiro. Embora no início das crises possam parecer localizadas, a lateralização e a localização não são consistentes de um ataque para outro. As crises generalizadas podem ser assimétricas, geralmente ocorre perda de consciência inicial, com fenômenos motores bilaterais e grosseiramente simétricos (ILAE, 2010; MARINO JUNIOR, 1983).

São classificadas em crises de ausência, mioclônicas, clônicas, tônicas, atônicas e tônico-clônicas. No entanto, nesta abordagem enfatizou-se as crises de ausência e os casos mais comuns tônico-clônicos que apresentam diversas fases de uma crise generalizada, como apresentado a seguir.

2.7.2.1 Crises de Ausência

As crises de ausência são também denominadas como epilepsia de ausência da infância (EAI) ou pequeno mal. É uma forma de epilepsia de início pré-puberal e que ocorre em crianças sem quadro neurológico prévio. Como sintomatologia apresenta crise de ausência típica, inicialmente associada a paroxismos interictais⁶ e ictais de complexos espícula-onda lenta (CEOL) generalizados a 3 Hz (RAGAZZO, 2000). Caracterizam-se por crises epiléticas generalizadas em que o fator mais importante é a degradação do nível de consciência, apresentando as seguintes subdivisões (MARINO JUNIOR, 1983):

- Ausência típica – normalmente são crises de curta duração (5-15s), com plena clareza da consciência após o evento, caracterizando o “pequeno mal”. Ocorre uma ausência virtual das atividades psíquicas e geralmente acomete as crianças. A única modificação motora é um batimento palpebral com frequência de 3 Hz, sem qualquer alteração no tônus postural. São também muito freqüentes “microausências” de menos de 5 segundos, sendo a degradação da consciência variável. As ausências típicas são raras após a adolescência e são facilmente provocadas com hiperventilação (MARINO JUNIOR, 1983).
- Ausência atípica - de acordo com Marino Júnior (1983), esse tipo de ausência caracteriza o “pequeno mal variante”. Nessas crises existem com freqüência manifestações motoras tônicas. Normalmente apresentam anormalidades neurológicas ou psíquicas e lesões cerebrais, sendo que os grupos musculares mais afetados são os elevadores da pálpebra e globos oculares. Nos casos mais graves ocorrem contrações tônicas dos músculos cervicais posteriores, elevadores dos ombros e mastigadores. A degradação da consciência é variável, sendo as ausências atípicas breves, em torno de 5 segundos. Os pacientes não respondem a hiperventilação e em termos de contexto clínico os sintomas são bem diferentes das ausências típicas, cujos indivíduos são neurologicamente e psiquicamente normais.

⁶ Interictal – corresponde ao período anterior e posterior às crises (MARCHESI, 1998).

- Ausência complexa - além de afetarem a consciência dos pacientes, acompanham efeitos motores e/ou vegetativos, que na maioria das vezes acabam sendo o aspecto mais marcante em termos clínicos.
- Ausência mioclônica - em crises de ausências pode ocorrer o componente mioclônico (contrações musculares súbitas) envolvendo grupos musculares cefálicos, músculos do tronco ou todo o corpo. Normalmente as características são severas e de difícil tratamento, pois em geral acompanha as ausências atípicas no contexto da síndrome de Lenox-Gastaut⁷ (MARINO JÚNIOR, 1983). Quanto a esta síndrome, em Cambier, Masson e Dehen (1999) apontam para uma associação com vários tipos de crises como: crises tônicas ou hemitônicas, crises atônicas (que podem causar uma queda total ou, quando limitado à nuca, apresenta queda da cabeça) e crises tônico-clônicas generalizadas. A síndrome está relacionada com ausências atípicas marcadas por um obscurecimento da consciência (CAMBIER, MASSON e DEHEN, 1999).
- Ausência com componente tônico – nestes casos, as crises de ausência acompanham as contrações tônicas de diversos grupos musculares. Pode-se observar em grau elevado nas crises atípicas (MARINO JUNIOR, 1983).
- Ausência com automatismo - os automatismos podem ser do tipo ambulatório (relativo à marcha), com fugas mais ou menos organizadas do tipo manipulativo no momento em que o indivíduo tem a consciência alterada. Ocorrem no período ictal ou pós-ictal nos estados de mal de ausência, tanto nas crises típicas como atípicas (MARINO JUNIOR, 1983).
- Ausência com fenômeno autonômico - trata-se dos efeitos que ocorrem nas crises de ausência com diversas alterações vegetativas tais como: alterações do ritmo cardíaco e respiratório, sudorese, alterações pupilares, lacrimação, salivação e outros. Estas alterações acompanham as crises generalizadas ou

⁷ A síndrome de Lennox-Gostaut é uma encefalopatia epiléptica dependente da idade, classificada como síndrome epiléptica generalizada criptogênica ou sintomática. Apresentam crises generalizadas multiformes, alta frequência de crises, anormalidades eletroencefalográficas severas e quase contínuas, múltiplas etiologias, associação praticamente constante com retardamento mental e intratabilidade farmacológica das crises (MELO-SOUZA, 2000).

podem constituir toda a sintomatologia crítica (quando isto ocorre podem ser denominadas de crises autonômicas) (MARINO JUNIOR, 1983).

2.7.2.2 Crises Tônico-Clônicas

As crises generalizadas podem apresentar manifestações clônicas com movimentos motores idênticos a fase clônica de uma crise generalizada tônico-clônica, acometendo as crianças na primeira infância, sendo a febre o principal motivo desencadeante destas crises (MARINO JUNIOR, 1983). Em outras situações, podem acometer o paciente como uma crise tônica assemelhando-se à fase tônica flexora da crise tônico-clônica generalizada.

As crianças nas ausências atípicas são as mais afetadas com as crises freqüentes da síndrome de Lennox-Gastaut, com crises de curta duração (em torno de 10 segundos), onde existe o estado de mal tônico e manifestações tônicas lentas associadas à atividade autonômica de hipersecreção brônquica, que pode levar à morte por insuficiência respiratória (MARINO JUNIOR, 1983).

Ainda podemos citar as crises mioclônicas como uma derivação das crises generalizadas, onde ocorrem abalos musculares bilaterais e sincrônicos (simétricos), que acometem os indivíduos na fase da adolescência (entre os 13 e 20 anos). As crises acontecem com mais freqüência pela manhã, logo após despertar. Podem acontecer agrupadas em surtos rápidos ou isoladas, e atingir os membros superiores ou, em menor incidência, os inferiores (podendo provocar queda). Está associada ao histórico familiar e a estimulação luminosa intermitente favorece o surgimento das crises mioclônicas e a avaliação eletroencefalográfica, sendo que a consciência não é afetada quando a mioclonia é isolada (CAMBIER, MASSON e DEHEN, 1999, p. 158; MARINO JÚNIOR, 1983).

No entanto, as crises generalizadas com registros mais antigos, temidas e dramáticas da literatura universal são as crises tônico-clônicas. Devido à facilidade e evidência no reconhecimento destas crises, são as crises mais prevalentes nos pacientes com epilepsias. Os termos “convulsão generalizada” e “crise motora

maior”, tendem a ser substituídos pelo ainda utilizado “grande mal” (GUERREIRO, 2000).

Numa crise tônico-clônica generalizada há perda de consciência imediata, contração intensa tônica muscular dos membros, coluna vertebral, tórax e face e como conseqüência apnéia⁸, cianose⁹ e mordedura da língua (CAMBIER, MASSON e DEHEN, 1999). Em seguida, seguem abalos clônicos generalizados, como também a atonia (perda de tônus muscular) e recuperação gradual da consciência. Podem ocorrer ferimentos como: fraturas, sangramentos, mordedura de língua e incontinência esfinteriana (ANDRÉ, 1999).

2.8 Resumo

Neste capítulo foram apresentados os principais tipos de tremores associados com patologias graves e que causam grande desconforto à população afetada. Conforme já exposto, muitos destes distúrbios ainda não apresentam cura, como também um diagnóstico clínico ineficaz, pode indicar um tratamento equivocado. Por isso, é tão importante o estudo e discussão de todos os conhecimentos científicos existentes para o aprimoramento dos diagnósticos e tratamentos dos distúrbios dos movimentos que acometem os seres humanos (DEUSCHL, BAIN e BRIN, 1988).

⁸ Apnéia corresponde à interrupção voluntária ou involuntária da respiração.

⁹ Cianose está associada ao sintoma marcado pela coloração azul-arroxeadada da pele.

3 MÉTODOS UTILIZADOS NA CAPTURA, DETECÇÃO E CLASSIFICAÇÃO DE MOVIMENTOS EM SERES HUMANOS – ESTADO DA ARTE

Neste capítulo, serão apresentados alguns trabalhos publicados recentes e com importantes contribuições relativas ao uso de acelerômetros para a aquisição e detecção de tremores, bem como o uso de redes neurais ou métodos similares para a classificação dos mesmos.

Os métodos tradicionais, tais como eletroencefalograma (EEG) e videomonitoração (para análise de um profissional qualificado), são eficientes para a detecção de tremores, mas não permite que o paciente seja monitorado fora do ambiente hospitalar ou realizando as atividades normais do cotidiano. Mesmo em ambiente hospitalar, a videomonitoração é prejudicada quando o paciente estiver utilizando um cobertor. No estudo de Cuppens *et al.* (2009), como parâmetros de detecção das crises, além do eletroencefalograma e videomonitoração, foram utilizados os dados de eletrocardiograma (ECG) e eletrooculograma (EOG) sincronizados com os dados de cinco acelerômetros. Isto constitui um diferencial em relação a outros trabalhos (CUPPENS *et al.*, 2009).

Na pesquisa de Cuppens *et al.* (2007), o acelerômetro foi utilizado para a detecção de crises de epilepsias noturnas de pacientes pediátricos. Foram utilizados quatro acelerômetros, um em cada membro do corpo (extremidades), com o objetivo de capturar movimentos de componentes motoras (contrações musculares). As amostras capturadas foram filtradas através do cálculo de um valor de “limiar”, de modo a considerar apenas os movimentos mais significativos (suspeitos de uma crise de epilepsia). Com a aplicação deste procedimento, o processamento dos dados é significativamente reduzido por considerar somente as amostras que apresentam movimentos anormais.

A figura 1 apresenta os sinais capturados por acelerômetro, considerando como resultado o cálculo da média da energia das últimas n amostras. A energia do sinal está diretamente associada à amplitude e intensidade dos movimentos. Como existe uma pequena diferença comparando-se a amplitude do braço esquerdo em (a) com a perna esquerda em (b), o cálculo do “limiar” foi diferente para os dois casos. Neste estudo, tal cálculo é utilizado como uma “barreira” ou critério para a

detecção de uma crise de epilepsia, o que ocorre quando o nível de energia do sinal ultrapassar este valor em pelo menos dois sensores (dos quatro colocados no paciente) (CUPPENS *et al.*, 2007).

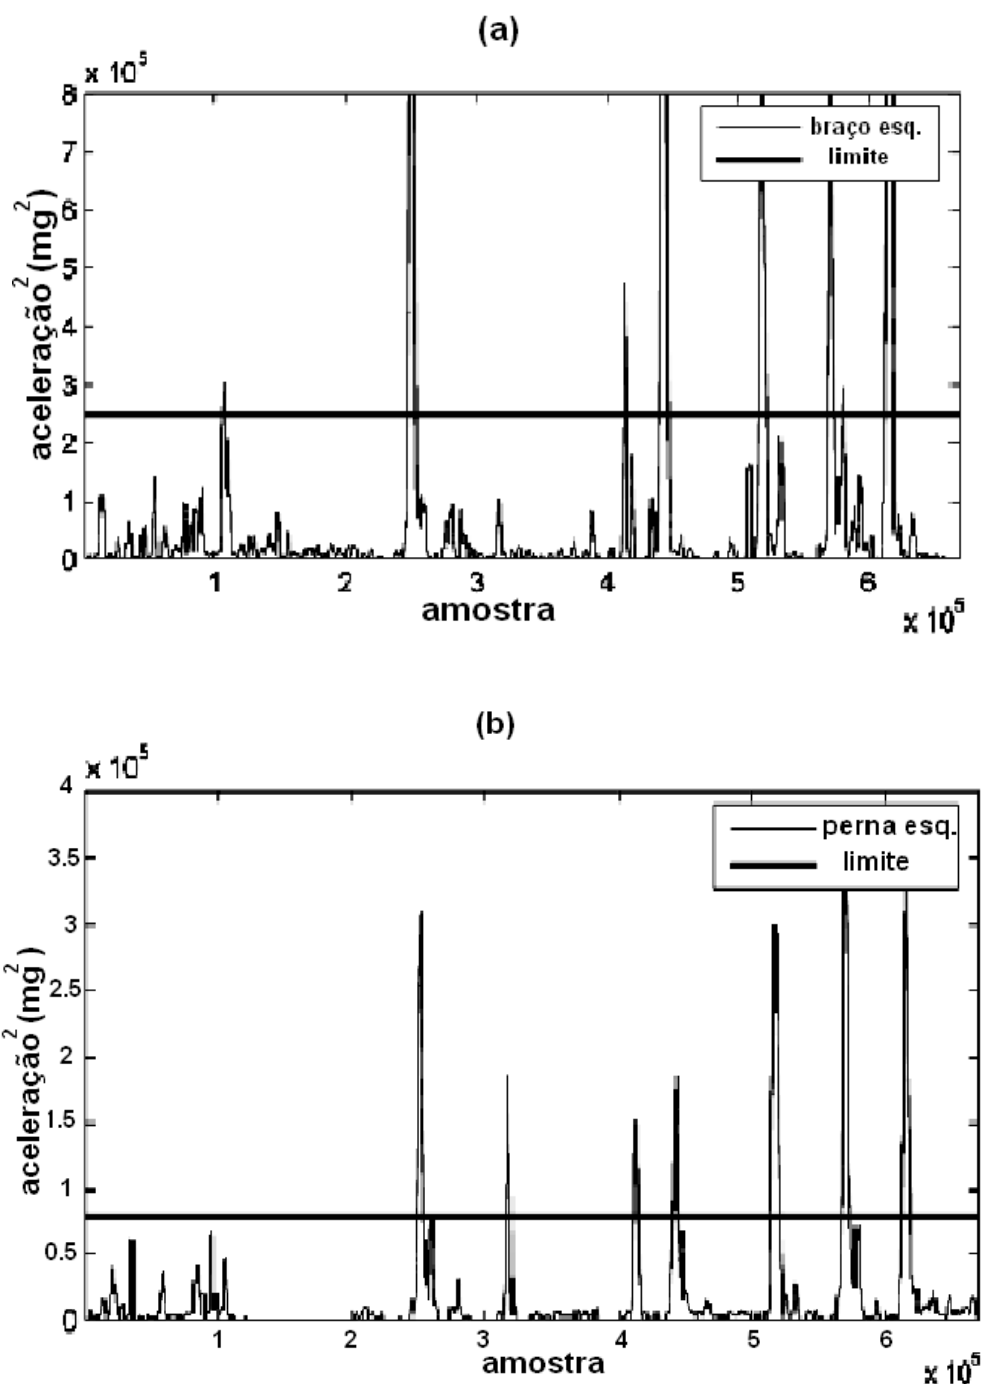


Figura 1 - Em (a) e (b) os gráficos apresentam a energia de captura dos acelerômetros colocados no braço esquerdo e perna esquerda respectivamente, com o "limiar" calculado representado na horizontal e diferenciado para ambos.

Fonte: Adaptado de Cuppens *et al.* (2007).

Em Burchfield e Vendatesan (2007), para detectar crises/convulsões de pacientes epiléticos, os movimentos dos braços são monitorados utilizando o dispositivo acelerômetro na forma de redes de sensores sem fio para o acionamento de alarmes. Outro conceito importante inserido neste artigo, e utilizado como condição para o acionamento do alarme, consiste na determinação de um tempo de repetição dos movimentos amplos ou anormais (que ultrapassam o “limiar” estabelecido) de modo a considerá-los como uma crise de epilepsia.

Alarmes falsos ou falsos positivos para movimentos normais do cotidiano podem ser eliminados com o emprego desses conceitos. A figura 2 mostra um exemplo que considera um “limiar” $G_{mín}=90$ como critério para o início de uma contagem, o que ocorre em $T_{mín}=0$. Se a amplitude do sinal permanecer acima deste nível durante um tempo mínimo de 15 amostras consecutivas, o alarme é disparado.

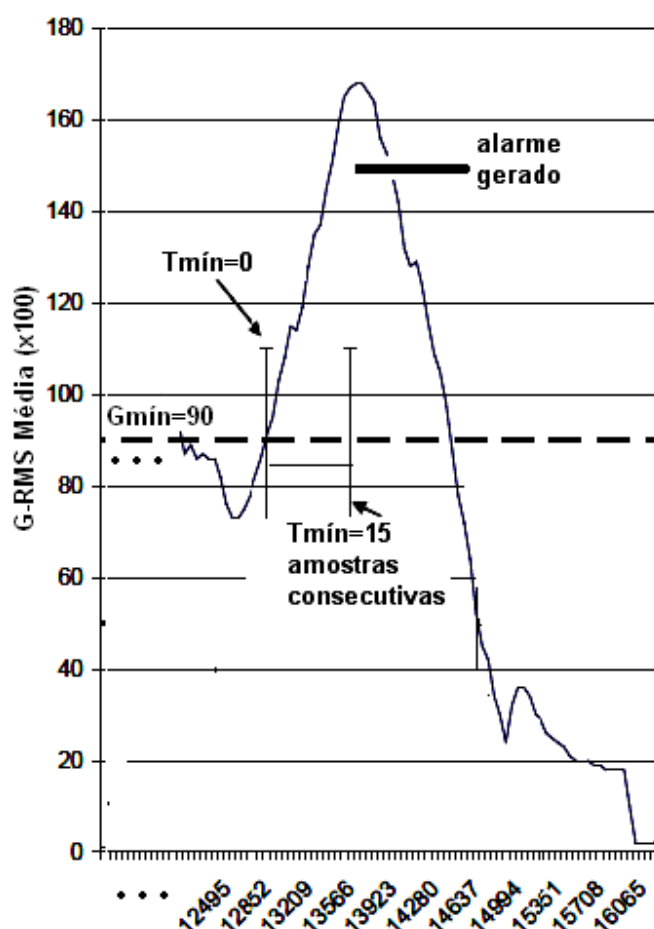


Figura 2 - O gráfico mostra a necessidade de duas condições para o acionamento do alarme. A amplitude do movimento deve ultrapassar $G_{mín}=90$ (primeira condição) durante um tempo mínimo ($T_{mín}=15$) amostras consecutivas (segunda condição).
Fonte: Adaptado de Burchfield e Vendatesan (2007).

Em Elevant (1999), um relógio de pulso contendo um sensor de movimentos baseado no componente acelerômetro foi colocado no pulso de pacientes portadores de epilepsia para o acionamento automático de alarmes. Um *software* baseado em algoritmos específicos deve distinguir movimentos de atividade normal do cotidiano de movimentos anormais de crises de epilepsia. A figura 3 mostra a forma como os dados foram capturados nos experimentos, que consideraram pacientes epiléticos deitados dormindo ou descansando em ambiente hospitalar.




Figura 3 - O sensor de movimento é preso ao pulso de voluntários e os dados são armazenados em um computador para o processamento *off-line*.
Fonte: Elevant (1999, p. 14).

Um aspecto importante da pesquisa de Elevant (1999) foi a elaboração de um novo sinal a partir do sinal original. Na figura 4, o sinal original recebe um tratamento de modo a gerar um sinal que sempre excede o original, ou seja, um sinal que contorna os pontos de máximo, além de acrescentar um tempo para chegar a zero (decaimento do sinal lento na rampa de descida por um determinado tempo para chegar a zero). O aspecto do sinal pode ser observado no gráfico central. O objetivo é o acionamento de um alarme projetado com base no *Laboratory Virtual Instrument Engineering Workbench* (Labview) utilizando como parâmetros de entrada o novo sinal gerado, um nível de “limiar” de tensão e o tempo de duração dos movimentos (tempo de janela).

Algumas condições foram adicionadas para a avaliação de alarmes falsos pelos algoritmos criados, como caminhada, arranhando, batendo as mãos, lavando pratos e colocação e retirada do dispositivo do pulso. A condição batendo palmas foi a mais crítica causando alarmes falsos. Elevant (1999) também sugere a utilização de outros sensores ou novos parâmetros para diminuir a possibilidade de falsos alarmes como: frequência cardíaca, pressão arterial e nível de oxigenação no sangue.




Figura 4 - Diagrama em blocos de um alarme onde o sinal original é transformado em um novo sinal que sempre excede o original.

Fonte: Adaptado de Elevant (1999, p. 15).

A pesquisa de Khan *et al.* (2010) utilizou diversos acelerômetros com o objetivo de monitorar pacientes idosos, obtendo-se avaliações de atividades diárias de longo prazo. Um diferencial importante é que os dispositivos sensores foram colocados nos bolsos da camisa, calça e no peito dos pacientes, permitindo grande flexibilidade na aquisição dos dados. Os dados foram gravados *off-line* e depois processados para a avaliação do estado de saúde e tratamento como um todo. As atividades foram realizadas nas próprias casas, evitando internamentos desnecessários e um acompanhamento mais preciso das atividades realizadas pelos pacientes. Os acelerômetros foram utilizados como sensores, principalmente pelo baixo consumo, tamanho físico e baixo peso, evitando vários desconfortos aos pacientes idosos. Foram validados dados capturados de sete atividades físicas de cinco posições diferentes (locais do corpo para a aquisição de dados).

O diagrama em bloco das fases de processamento desenvolvido por Khan *et al.* (2010) pode ser observado na figura 5. Na fase (a) os sinais dos acelerômetros foram filtrados para eliminar ruído. Na fase (b), as atividades objetos de estudo foram classificadas através do cálculo da potência espectral para as frequências detectadas nas aquisições pelos acelerômetros em: atividades de repouso, atividades dinâmicas dos movimentos que envolvem a parte superior do corpo e atividades dinâmicas da parte inferior do corpo. Em (c) e (d) um método estatístico que calcula a modelagem auto-regressiva (AR) (toma como base os valores passados para estimar valores atuais) foi utilizado na classificação das atividades dinâmicas. A combinação com o cálculo da área associada à magnitude do sinal (SMA) melhorou o índice de acertos na classificação. Uma abordagem de classificação supervisionada estatística de segunda ordem (LDA) foi utilizada para otimizar a classificação dos dados. Na sequência, em (c) e (d) uma rede neural do tipo *Multi-Layer Perceptron* (MLP) realizou a classificação dos dados em duas classes supervisionadas: atividades dinâmicas da parte superior do corpo (DUNN) e atividades dinâmicas da parte inferior do corpo (DLNN). Por fim, as diferentes atividades classificadas nos experimentos foram: repouso (deitado / sentado / em pé), caminhada (no corredor), subir escada, andando (andar de cima e térreo), corrida, ciclismo e aspiração. Neste estudo, alguns métodos de classificação como árvores de decisão, redes Bayesianas, cadeias de Markov e redes neurais foram testados. Os melhores resultados foram obtidos com redes neurais na avaliação dos dados capturados pelos acelerômetros.

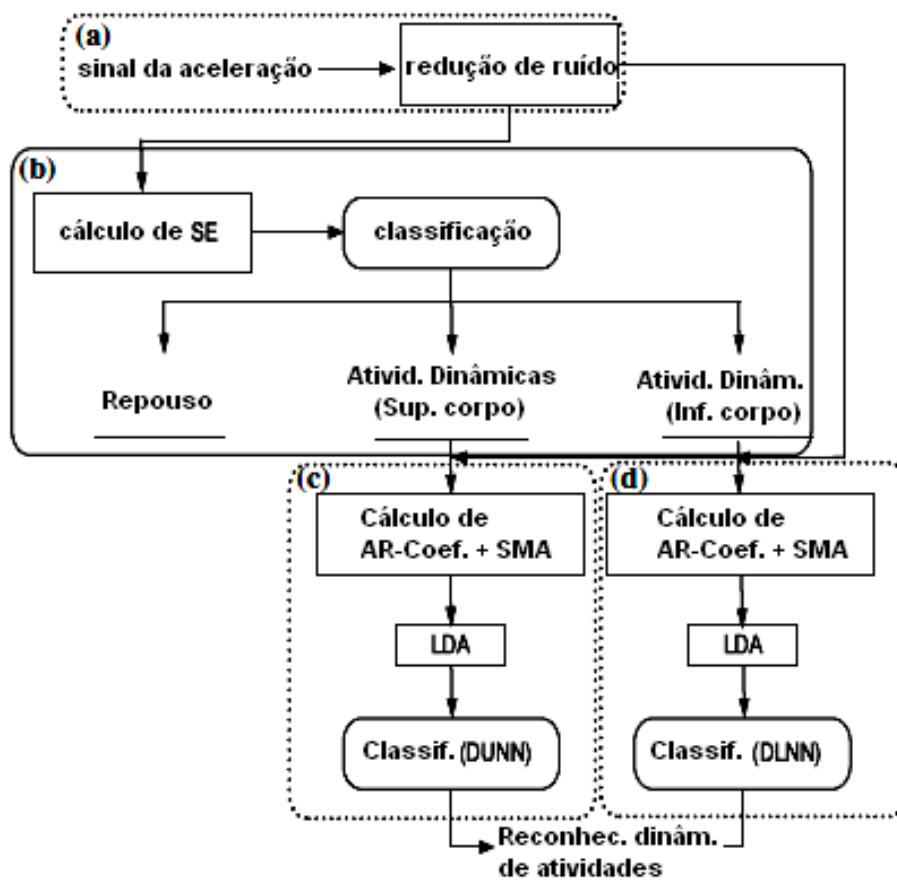


Figura 5 - Diagrama em blocos das fases de processamento dos sinais capturados por acelerômetros.

Fonte: Adaptado de Khan (2010, p. 1275).

Na pesquisa de Winter (1999) foram realizados experimentos para avaliar o nível de tremor humano em repouso. Algumas pessoas voluntárias participaram da pesquisa que utilizou um sistema com sensor não invasivo para captura de movimentos de tremores associados a diferentes graus de estresse psicológico. Foi construído um medidor baseado em um acelerômetro piezoelétrico¹⁰, utilizando o princípio do detector inercial, que reflete uma medida da aceleração dos movimentos. Uma análise gráfica de espectros de frequência e valores médios de amplitude foram alguns dos parâmetros utilizados neste estudo. Esta ferramenta deve auxiliar os médicos na análise da evolução clínica e no tratamento de portadores da doença de Parkinson, usuários de drogas, alcoolismo ou tensões diárias.

¹⁰ Os acelerômetros piezoelétricos possuem cristais sintéticos ou naturais, que ao serem comprimidos ou fletidos, geram uma diferença de potencial proporcional a vibração que o corpo do acelerômetro foi submetido (FIQUEIREDO et al., 2007).

Um sistema automatizado para aquisição de sinais e auxílio à avaliação clínica de tremor em seres humanos foi desenvolvido por Cichaczewski e Cunha (2008). Trata-se de uma ferramenta para auxiliar no diagnóstico da doença de Parkinson e o tremor essencial, bem como outras patologias associadas com tremores, fornecendo parâmetros para a identificação dos sintomas e o posterior tratamento. Utilizaram-se diversos sensores colocados em pontos estratégicos para a aquisição dos sinais de tremores, tomando como base o componente eletrônico integrado acelerômetro. Os dados são armazenados em tempo real em um computador e processados por um *software* que calcula a frequência dos sinais (através da transformada rápida de Fourier (FFT)) e a amplitude média como parâmetros suficientes para auxiliar o médico em avaliações clínicas.

Acelerômetros são utilizados no trabalho de Graham (2000) para a avaliação de tremores de mãos involuntários, comuns na doença de Parkinson e tremor essencial. Os tremores relacionados com essas patologias constroem as pessoas em atividades normais do cotidiano no simples ato de escrever, comer ou beber. O exame mais comum para o registro de contrações musculares nos hospitais é a eletromiografia (EMG), a qual registra os sinais correspondentes aos impulsos elétricos de contrações musculares (podendo ser invasivo ou não invasivo). O estudo de Graham (2000) demonstra uma aplicação médica futura, onde os acelerômetros fornecem sinais elétricos tomando como base a aceleração dos movimentos, de modo não invasivo e apresentando outras vantagens como: baixo custo, pequenas dimensões físicas, de fácil instalação e podendo ser adaptado facilmente em diversos pontos do corpo (cabeça, pescoço, dedos das mãos, braços, pernas e outros). Na figura 6, o sensor com o acelerômetro foi colocado em um dos dedos da mão dos pacientes para realizar as aquisições de movimentos voluntários e involuntários. O módulo sensor acompanha uma placa de circuito impresso adaptada no braço, que estabelece a comunicação via cabo com outra placa de circuito impresso de base que se comunica com um *laptop* para o armazenamento e o processamento das informações relativas aos movimentos objetos de estudo. No estudo de Graham (2000), o tamanho do sensor foi uma das preocupações nos experimentos, ou seja, deve ser pequeno para não interferir nas medições, com cabos para as conexões leves e flexíveis quando necessários.




Figura 6 - Aquisição de dados de tremores com sensor acelerômetro colocado no dedo da mão. A placa de circuito impresso de base estabelece a comunicação com o computador para o armazenamento e processamento dos dados.

Fonte: Adaptado de Graham (2000, p. 13).

Um sistema automatizado através de alarmes em tempo real foi utilizado para a detecção de crises de epilepsia com sintomas motores (NIJSEN, 2008). De acordo com Nijsen (2008), 25% dos pacientes são refratários aos tratamentos e apresentam crises recorrentes, além de apresentarem retardo mental na maioria dos casos. Sendo assim, um sistema de detecção com uso de acelerômetros para realizar um acompanhamento diário das crises é plenamente justificável. Foram utilizados diversos acelerômetros, os quais apresentaram grande eficiência quando comparados com a observação visual realizada por profissionais especializados.

O atendimento rápido é importante principalmente nos casos em que os pacientes necessitam de intervenções urgentes. Para se obter um diagnóstico mais preciso do tipo de crise, da sua frequência e a distribuição durante o dia e a noite, normalmente realiza-se um acompanhamento de longo prazo para uma análise clínica mais detalhada.

O sistema com a utilização de acelerômetros apresentou grande potencial para a detecção de crises quando empregado em conjunto com EEG e monitoramento de vídeo. Excelentes resultados foram obtidos na detecção de crises em 36 horas de gravações (NIJSEN, 2008). O programa Matlab foi utilizado para a análise das características dos sinais capturados pelos acelerômetros (nos pulsos, tornozelos e no tórax) no momento de uma crise de epilepsia, combinando os dados de EEG com os dados gravados em vídeos.

O sucesso da classificação dos dados, de acordo com Nijssen (2008), tem como prioridade a qualidade das características extraídas, não dependendo tanto da complexidade do classificador. A figura 7 apresenta um bloco “padrão” e um bloco “algoritmo” para a avaliação de eventos de crises de epilepsia. No primeiro bloco, dados armazenados de EEG com gravações de vídeo e os sinais capturados dos acelerômetros (todos sincronizados) incluindo anotações (experiências) são analisados por especialistas (médicos, enfermeiros, técnicos, etc.). No segundo bloco, os sinais capturados dos acelerômetros são validados para a extração de características que servirão de base para a classificação dos dados por um elemento classificador (algoritmo específico para a classificação). Os resultados obtidos nos dois blocos são executados em paralelo e comparados para a tomada de decisão (diagnóstico, tratamento, etc.).

A abordagem de aprendizado com reconhecimento de padrões supervisionados foi adotada no estudo de Nijssen (2008), prevalecendo a análise de frequências dos sinais pela transformada de Fourier e a transformada de *wavelet*. Outro aspecto importante foi a análise de duração (tempo) e a intensidade dos sinais de crises de epilepsia.

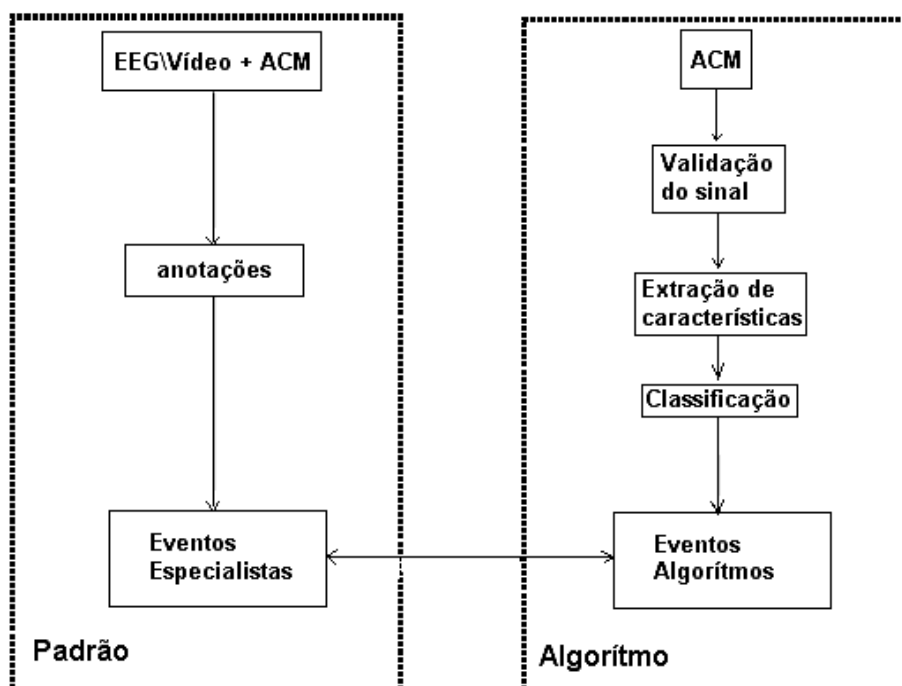


Figura 7 - Os dois blocos "padrão" e "algoritmo" são procedimentos executados em paralelo e comparados no final.

Fonte: Adaptado de Nijssen (2008, p. 9).

No estudo de Nijsen (2008) são estudados movimentos de crises epiléticas com movimentos amplos, nos casos tônico-clônicos, bem como, as crises tônicas que não apresentam a fase clônica, ou seja, somente tonicidade muscular (movimentos mais lentos). Nos casos tônico-clônicos são utilizados principalmente os parâmetros dinâmicos dos movimentos (amplitude e frequência) e nas crises tônicas a característica angular é preponderante na diferenciação ou classificação dos movimentos objetos de estudo.

Na figura 8, na pesquisa de Nijsen (2008), são apresentados alguns exemplos de sinais envolvendo movimentos anormais e normais capturados de humanos com a utilização de acelerômetros triaxiais. Apesar dos movimentos normais serem citados no estudo de Nijsen (2008), não houve um aprofundamento sobre estes movimentos, sendo o foco principal os movimentos anormais de crises de epilepsias. O gráfico (a) mostra os movimentos característicos de uma crise tônica, iniciando com uma lenta mudança de postura aliado, à presença visível de um pequeno tremor na continuidade dos sinais, caracterizando o comportamento de uma crise tônica de epilepsia. O gráfico (b) mostra a transição entre as fases tônica e clônica de uma crise tônico-clônica de epilepsia. O gráfico (c) apresenta um movimento normal caracterizado como “lento” e de baixa frequência, enquanto no gráfico (d) mostra um movimento normal caracterizado como “rápido” com picos de onda e denotando uma frequência maior.

Considerando as contribuições de Nijsen (2008) sobre a detecção de crises epiléticas tônicas, os principais fatores ou características utilizadas na diferenciação de outros tipos de movimentos, incluindo os tipos de crises e movimentos normais do cotidiano, são: baixa amplitude, baixa frequência, a duração (tempo) e a inclinação do sinal. Um movimento normal de mudança de postura pode até assemelhar-se aos movimentos de uma crise de epilepsia, mas a duração do movimento e a inclinação são fatores distintos que facilitam a detecção de uma crise tônica. Foi feita uma análise da posição do sensor em relação ao vetor de gravidade, resultando em um valor de *offset* e, como consequência, obtém-se um parâmetro postural. Após a elaboração de todas as características, o processamento foi realizado através de uma análise estatística discriminante linear para gerar uma classificação final.

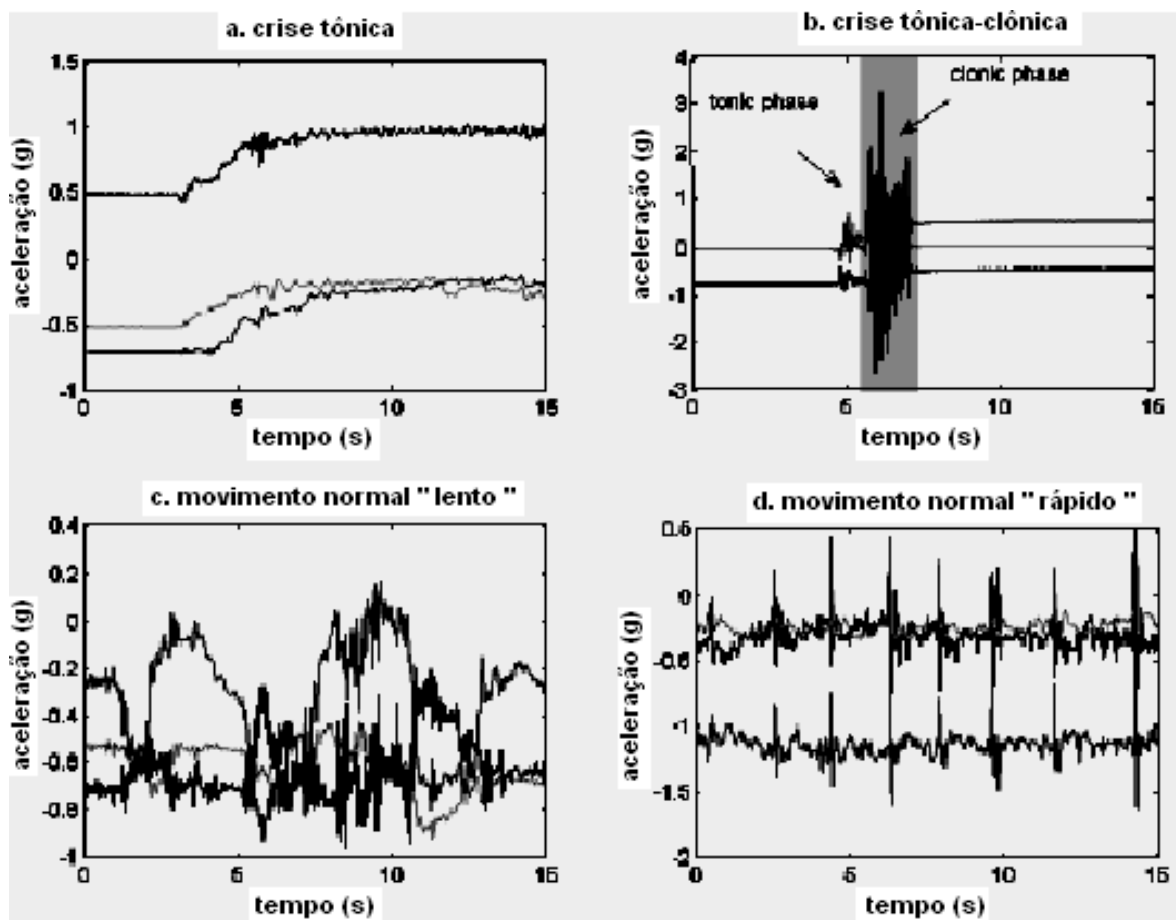


Figura 8 - Exemplos típicos de sinais capturados no braço com acelerômetro 3-D. O gráfico (a) mostra os sinais de uma crise tônica. O gráfico (b) mostra os sinais de uma crise tônico-clônica. O gráfico (c) mostra os sinais de movimentos normais virando folhas. O gráfico (d) mostra os sinais de movimentos normais batendo um objeto na mesa.

Fonte: Adaptado de Nijsen (2008, p. 91).

Na pesquisa de Mathie *et al.* (2004), uma base diária de diversos movimentos realizados por humanos foi capturada com a utilização de um acelerômetro triaxial colocado na cintura, tais movimentos foram processados com base em um algoritmo de árvore de classificação binária e divididos em classes e subclasses de acordo com os níveis hierárquicos, ou seja, movimentos de atividades e repouso. As atividades principais executadas nos experimentos foram: quedas, caminhando, orientações transitórias entre posturas e outros movimentos. As orientações posturais durante o repouso foram classificadas como: sentado, em pé ou deitado. Um conjunto de movimentos foi executado em laboratório por 26 sujeitos normais e saudáveis, totalizando 1309 movimentos capturados.

A figura 9 apresenta um dos algoritmos de classificação utilizados nos experimentos realizados por Mathie *et al.* (2004), mostrando apenas dois níveis de hierarquia da árvore de classificação binária. As classes são identificadas no início

do algoritmo (acima dos pontilhados) e são classificadas como “atividades”. As subclasses ou “orientações posturais” serão identificadas a partir da classificação de hierarquia superior (pai) como sub-movimentos nos níveis inferiores. Sendo assim, ao iniciar o processamento (ver figura 9) um movimento de atividade “movimento 1” de acordo a condicional, se classificado como “sim”, prossegue no próximo nível (abaixo dos pontilhados) com uma nova condicional para testar a existência de uma subclasse “sub-movimento 1”, se classificado como “sim” será identificado como “sub-movimento 1”, se o resultado da condicional for “não” será classificado como “sub-movimento 2”. O processamento continua com a identificação de todas as classes e sub-classes, obedecendo a sequência de execução para os diversos níveis da árvore de classificação binária.

No entanto, existem muitas abordagens diferentes que poderiam ser aplicadas na classificação dos movimentos objetos de estudo, incluindo regras heurísticas, lógica *fuzzy* ou modelagem estatística comportamental, como cadeias de Markov (MATHIE *et al.*, 2004).

Os resultados obtidos na pesquisa de Mathie *et al.* (2004) evidenciam a eficácia do método utilizado, obtendo como classificações corretas em todos os níveis da hierarquia no algoritmo de árvore binária, uma sensibilidade de 97,7% e especificidade de 98,7%, considerando um conjunto de dados de 1309 movimentos objetos de estudo.

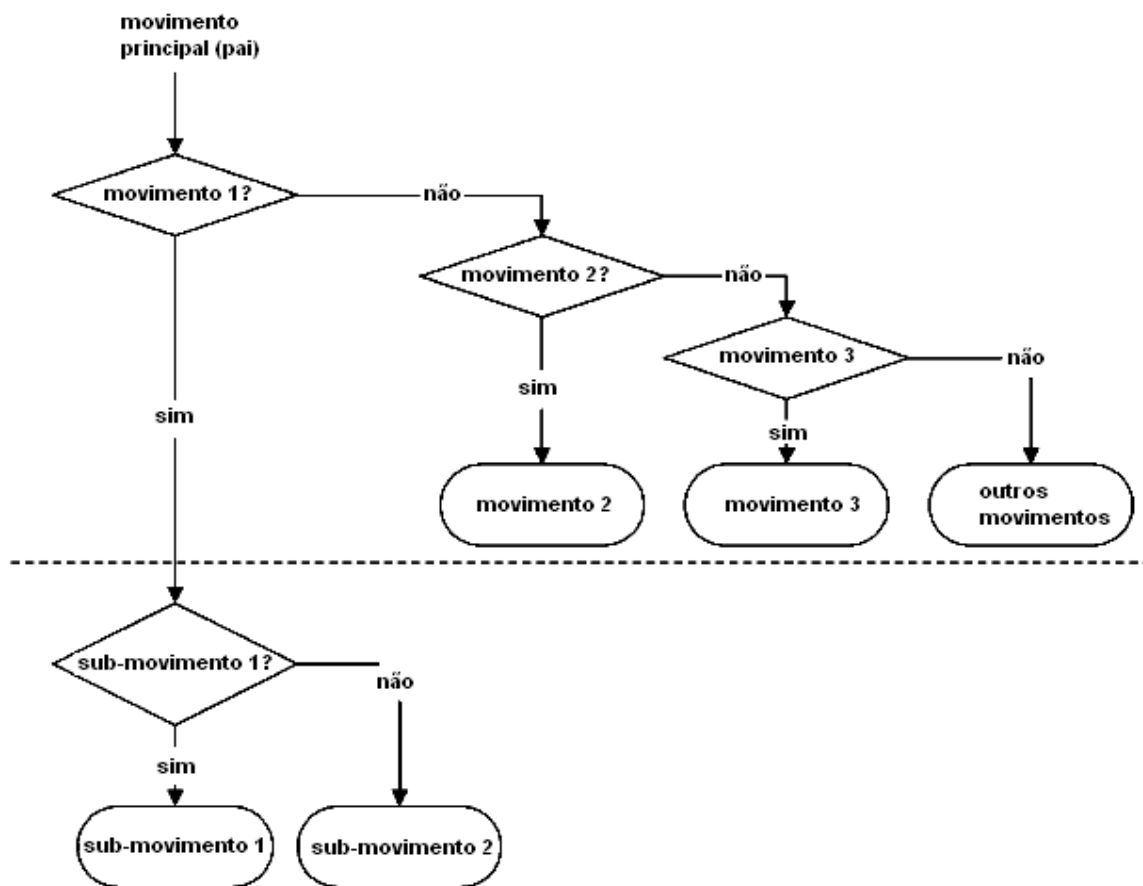


Figura 9 - Quadro de classificação estruturado como árvore binária. Acima do pontilhado corresponde aos movimentos de atividades (classes). Abaixo do pontilhado corresponde às orientações posturais (sub-nível ou sub-classe).

Fonte: Adaptado de Mathie (2004, p. 680).

3.1 Redes Neurais Artificiais (RNAs)

Entre as principais técnicas de Inteligência Artificial (IA) estão as Redes Neurais Artificiais (RNAs), a lógica difusa (*fuzzy logic*), redes bayesianas, algoritmos genéticos e sistemas baseados em regras ou em casos, etc.

As RNAs, consideradas nesta dissertação, apresentam um vasto campo de aplicações como: modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle e outras. Esta técnica pode ser aplicada ao reconhecimento de imagens, movimentos, voz, assinaturas, diagnósticos médicos e outros (RAITZ, 2002).

Historicamente, pode-se dizer que as RNAs foram desenvolvidas em 1943 por McCulloch (fisiologista) e Pitts (matemático), os quais desenvolveram um modelo matemático baseado no modelo biológico de um neurônio. No entanto, por não apresentarem parâmetros livres não era possível treinar os neurônios desenvolvidos por McCulloch e Pitts. Mais tarde em 1949, Donald Hebb propôs uma lei de aprendizagem específica para sinapse dos neurônios, demonstrando que a teoria de McCulloch e Pitts necessitava de ajustes nos pesos sinápticos, similar ao que ocorre nas redes biológicas (AGUIAR, 2010; BABINI, 2006).

A figura 10 nos mostra três elementos básicos principais das RNAs (HAYKIN, 2001):

- a) As sinapses ou elos de conexões estão representados por um sinal x_j na entrada da sinapse j conectado ao neurônio k . Para cada um dos sinais de entrada, ocorre a multiplicação pelo peso sináptico W_{kj} . Os pesos podem assumir valores positivos e negativos.
- b) Um somador realiza a soma dos sinais de entrada ponderados pelas respectivas sinapses do neurônio k .
- c) Na função de ativação ocorre uma restrição a amplitude de saída do neurônio. O intervalo que define a amplitude de saída do neurônio é normalizado em um intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

Na figura 10, pode-se notar uma entrada de *bias* representada por b_k , cujo valor corresponde a um valor externo que tem finalidade de aumentar ou diminuir a entrada líquida da função de ativação, dependendo do valor ser positivo ou negativo, respectivamente.

De acordo com o exposto, a representação matemática é (HAYKIN, 2001)

$$u_k = \sum_{j=1}^m W_{kj} x_j \quad (1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (2)$$

Onde:

- u_k é o vetor ou combinador linear que armazena a soma ponderada dos m sinais de entrada do neurônio k ;
- W_{kj} corresponde aos pesos sinápticos $w_{k1}, w_{k2}, \dots, w_{km}$ do neurônio k ;

- x_j são os valores de entrada x_1, x_2, \dots, x_m ;
- $\varphi(\cdot)$ é a função de ativação;
- y_k corresponde ao sinal de saída do neurônio k .

Na figura 10 o vetor v_k pode ser representado como:

$$v_k = (u_k + b_k) \quad (3)$$

Sendo assim, a equação (2) (que apresenta a saída do neurônio k) pode ser reescrita como:

$$y_k = \varphi(v_k). \quad (4)$$

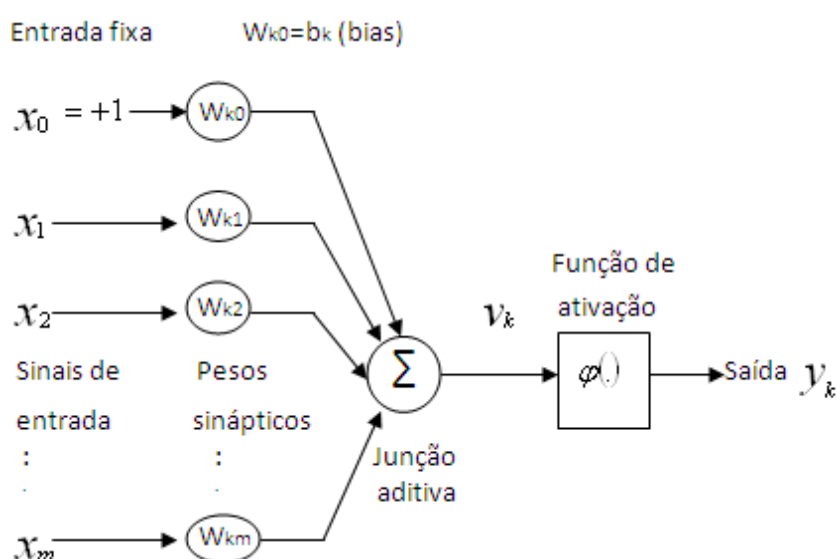


Figura 10 - Modelo não-linear simplificado de um neurônio artificial.
 Fonte: Adaptado de Haykin (2001, p. 38).

O algoritmo de aprendizagem utilizado para o treinamento da rede neural depende principalmente da distribuição e estruturação dos neurônios. As arquiteturas de redes mais comuns são (HAYKIN, 2001):

- Redes alimentadas adiante com camada única – a forma mais simples compreende uma única camada. Pode-se observar na figura 11 uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios, mas não vice-versa.




Figura 11 - Rede alimentada adiante ou acíclica com uma única camada de Neurônios (*feedforward*).

Fonte: Adaptado de Haykin (2001).

- b) Redes alimentadas adiante com múltiplas camadas – distingue-se pela presença de uma ou mais camadas ocultas. Apresenta maior interferência quando o tamanho da camada de entrada é grande. Os sinais de saída da segunda camada são utilizados como entradas da terceira camada e assim por diante. Um exemplo de rede neural que aplica este conceito são as redes *Multi-Layer Perceptron* (MLP), que são facilmente implementadas e muito difundidas. Estas características (figura 12) fazem com que sejam utilizadas no reconhecimento de padrões (ANGELO e KIMO, 2001; ZANCHETTIN e LUDERMIR, 2005; LUDWIG JÚNIOR, 2004; SANTOS *et al.*, 2003; GIL, 2010; AGUIAR, 2010).




Figura 12 - Rede alimentada adiante com múltiplas camadas de neurônios (*feedforward*).

Fonte: Adaptado de Haykin (2001).

- c) Rede recorrente – Este tipo de rede neural é distinta das anteriores por apresentar laço de realimentação (pelo menos um). Pode haver auto-realimentação, quando a saída de um neurônio é conectada a sua entrada; ou sem auto-realimentação quando a saída de um neurônio somente é conectada aos outros neurônios. A figura 13 apresenta um exemplo de rede neural recorrente auto-realimentada com neurônios ocultos (HAYKIN, 2001).

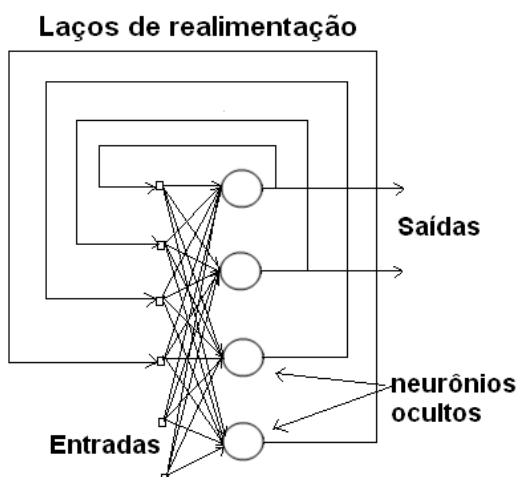


Figura 13 - Rede recorrente com camada única, laços de realimentação e neurônios ocultos.
Fonte: Adaptado de Haykin (2001).

As redes desenvolvidas por Hopfield (1982) são exemplos de redes com laço de realimentação e apresentam camada única com conexões retro-alimentadas entre os neurônios (AGUIAR, 2010; BABINI, 2006; HAYKIN, 2001).

A habilidade de assimilar a partir de seu ambiente e aprimorar o seu desempenho através da aprendizagem em uma rede neural é de importância primordial. Neste processo, considera-se a seguinte sequência de eventos (HAYKIN, 2001):

- A rede neural é estimulada por um ambiente (corresponde aos dados de entrada);
- A rede neural sofre modificações nos seus parâmetros livres como resultado desta estimulação (regras básicas de aprendizagem);
- A rede neural responde de uma maneira nova ao ambiente, devido às modificações realizadas na sua estrutura interna.

As principais regras de aprendizagem são: aprendizagem por correção de erro, aprendizagem baseada em memória, aprendizagem Hebbiana, aprendizagem

competitiva e aprendizagem de Boltzmann. A aprendizagem por correção de erro está fundamentada na filtragem ótima e foi utilizada na classificação dos movimentos humanos pela rede de múltiplas camadas (*feedforward*). A aprendizagem baseada em memória opera memorizando os dados de treinamento. As regras de aprendizagem Hebbiana e competitiva são mais aproximadas dos aspectos neurobiológicos (HAYKIN, 2001).

A aprendizagem por correção de erro é ilustrada na figura 14 considerando-se o caso simples de um único neurônio k , que representa um nó computacional da camada de saída de uma rede neural alimentada adiante (*feedforward*) (HAYKIN, 2001).

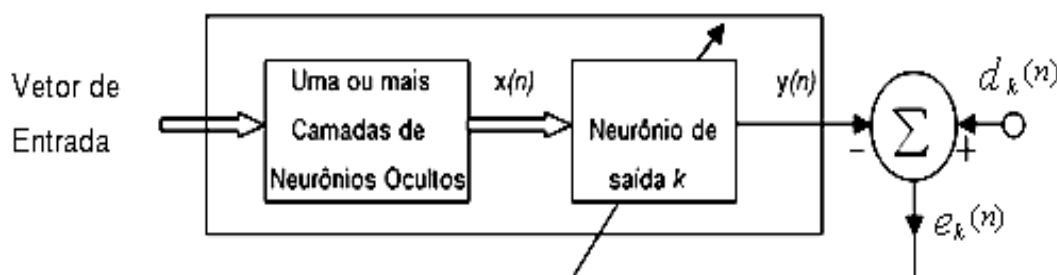


Figura 14 - Rede de múltiplas camadas alimentada adiante (*feedforward*), ressaltando o único neurônio da camada de saída, com a ilustração da aprendizagem por correção de erro.
 Fonte: Adaptado de Haykin (2001, p. 77).

Os dados do vetor de entrada estimulam uma ou mais camadas de neurônios ocultos. A saída $x(n)$ alimenta a entrada da camada de saída representada por um único neurônio k . O argumento n representa o passo de tempo de um processo iterativo que é realizado na atualização dos pesos sinápticos do neurônio k . Na saída deste, o sinal $y(n)$ é comparado com a saída desejada $d_k(n)$. Um sinal de erro $e_k(n)$ aciona um mecanismo de controle que realiza ajustes corretivos aos pesos sinápticos do neurônio k . A equação que representa este processo é

$$e_k(n) = d_k(n) - y_k(n). \quad (5)$$

Baseado na equação (5), o ajuste passo a passo dos pesos sinápticos do neurônio k é realizado até atingir um estado de estabilidade, ou seja, a aproximação de $y(n)$ com o valor desejado $d_k(n)$. A função de custo ou índice de desempenho

$$E(n) = \frac{1}{2} e_k^2(n), \quad (6)$$

é definida em função do erro $e_k(n)$ e tem como objetivo a minimização do seu valor. Esta regra de aprendizagem é denominada “regra delta” ou regra de Widrow-Hoff (HAYKIN, 2001).

A variação do peso sináptico j em relação ao neurônio k no passo de tempo n é escrita por

$$\Delta W_{kj}(n) = \eta e_k(n) x_j(n), \quad (7)$$

Onde:

- $\Delta W_{kj}(n)$ representa a variação do peso sináptico j em relação ao neurônio k no passo de tempo n ;
- $x_j(n)$ o elemento que excita o neurônio k ;
- $e_k(n)$ sinal de erro para efetuar os ajustes; e
- η corresponde à taxa de aprendizagem.

A taxa de aprendizagem η , conforme pode ser observado na equação (7) é uma constante positiva que determina a taxa de aprendizado quando se avança um passo no processo de aprendizado. Desta forma, pode-se definir a “regra delta” considerando-se que o ajuste ocorrido em um peso sináptico de um neurônio é proporcional ao produto do sinal de erro pelo sinal de entrada da sinapse em questão (HAYKIN, 2001).

Na prática, a taxa de aprendizado, o número de camadas de neurônios, o número de neurônios nas camadas de entrada, intermediária e de saída, além da função de ativação são fornecidos para o treinamento da rede neural. Os valores de configuração da rede neural são escolhidos após várias tentativas de modo a convergir ou generalizar (ANGELO e KIMO, 2001).

Outro aspecto importante a ser considerado é como a rede neural se relaciona com o ambiente. Um dos paradigmas está associado à presença ou não de um supervisor, ou seja, as redes supervisionadas, quando as classes são identificadas no momento do treinamento e classificação dos dados e as redes não supervisionadas, quando as classes não são fornecidas e a rede neural consegue se auto-organizar (HAYKIN, 2001).

3.1.1 Redes Neurais Fuzzy

As redes neurais *fuzzy* baseiam-se na teoria dos conjuntos difusos (ou lógica *fuzzy* (nebulosa)), que utilizam graus de pertinência em conjuntos (RAITZ, 2002; GIL, 2010; LERMONTOV, 2009; PAO, 1989; COSME, 2011). Neste caso, os valores de saída de uma unidade da rede (neurônio) podem estar compreendidos no intervalo entre 0 e 1, diferentemente das redes que aplicam a lógica tradicional, assumindo valores absolutos: verdadeiro ou falso. A figura 15 apresenta os conjuntos difusos e clássicos de crianças. Para o caso dos conjuntos difusos, uma pessoa com 5 anos de idade pode estar sendo associado ao conjunto das crianças com o valor de pertinência de 0,9; enquanto uma pessoa de 11 anos, com o valor 0,3. Para o conjunto clássico uma pessoa com 11 anos deixa de ser criança subitamente, enquanto para o conjunto difuso existe uma transição bem mais suave (RAITZ, 2002).

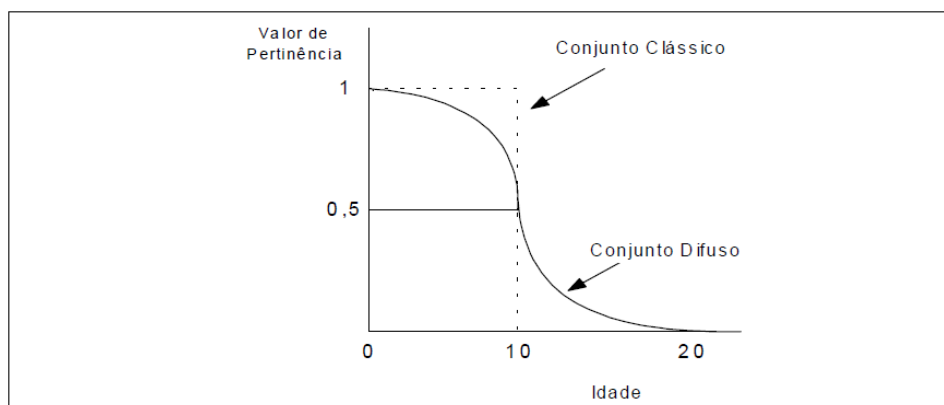


Figura 15 – Gráfico que representa um conjunto difuso e clássico de crianças.
Fonte: John Durkin (1994) apud Raittz (2002 p. 20)

A lógica *fuzzy* (lógica nebulosa) utilizada em redes neurais é uma ferramenta da Inteligência artificial (IA) que aborda o tratamento de incertezas e imprecisão de dados. Os modelos baseados em regras nebulosas podem representar aspectos qualitativos do conhecimento e dos processos de inferência humana, sem empregar análise quantitativa necessariamente precisa (LERMONTOV *et al.*, 2008; LERMONTOV, 2009). O estudo de Cosme (2011) apresenta um exemplo de aplicação de modelos baseados em lógica *fuzzy* na otimização nebulosa para

superar a dificuldade da modelagem das incertezas no problema da distribuição de energia elétrica.

3.1.2 Rede Neural Free Associative Neurons (FAN)

A rede neural do tipo FAN apresenta o conceito de livre associação de neurônios, sendo utilizada como um dos elementos classificadores nesta pesquisa. A arquitetura empregada nesta rede utiliza os princípios de uma rede *fuzzy* para o reconhecimento de padrões. Cada classe está associada a um espaço FAN ou um neurônio com características diferenciadas das redes conexionistas tradicionais, ou seja, utiliza uma lógica que usa graus de pertinência de conjuntos, em vez da pertinência e ausência absolutas: verdadeiro ou falso. A rede FAN é baseada no aprendizado conexionista e modelagem difusa (RAITZ, 2002). Alguns dos princípios que norteiam a rede FAN são os seguintes (RAITZ, 2002):

- O padrão é decomposto na vizinhança em torno do padrão de entrada. Tal vizinhança estabelece novos valores calculados, próximos ao padrão original, que correspondem a um conjunto de padrões difusos no espaço de entrada;
- Estabelecer as combinações entre as características que compõe os vizinhos;
- Por último é realizado a projeção da vizinhança difusa no espaço FAN obedecendo a uma função de pertinência triangular. Devem ser testadas as semelhanças entre as projeções e as classes do domínio do problema, alterando-as conforme os resultados;
- O algoritmo de aprendizado da rede FAN utiliza o conceito de “reforço” quando a classificação é correta e “penalização” para classificação incorreta.

3.2 Reconhecimento de Padrões (RP)

O reconhecimento de padrões (RP) é utilizado em diversas áreas da ciência como: engenharia biomédica, biologia, medicina, processamento de imagens e outros. O principal objetivo desta técnica é a classificação dos dados (RAITZ, 2002).

A utilização de redes neurais em RP é uma área em expansão e com excelentes resultados quando aplicado às diversas áreas da ciência, devido à grande capacidade de aprendizado a partir do ambiente (SANTOS *et al.*, 2003; BABINI, 2006).

No processo de RP, um universo de dados é submetido ao processamento para a extração e seleção das principais características que serão submetidas ao reconhecedor de padrões, objetivando a associação de classes ou classificação (LUDWIG JÚNIOR, 2004).

As redes neurais, quando utilizadas como ferramentas de classificação, podem resolver problemas com diversas variáveis de entrada, extraídas sobre espaços e correlações de dimensões elevadas para o reconhecimento de padrões. Observa-se que muitas das aplicações que utilizavam métodos estatísticos estão atualmente empregando soluções com RNAs, em particular para problemas de classificação e análise de dados voltados a área médica (SANTOS *et al.*, 2003).

O diagrama em blocos da figura 16 apresenta os procedimentos realizados no método de reconhecimento de padrões. O elemento sensor (a) é responsável por capturar os sinais dos movimentos objetos de estudo, os quais serão armazenados em um conjunto de dados (sinais) em (b). Em (c) o conjunto de dados será processado (*off-line*) para a elaboração das principais características que possam representar (a amplitude, a duração e a frequência dos sinais de entrada) e identificar os sinais capturados. As características devem ser analisadas e comparadas em uma seleção criteriosa, onde os recursos (parâmetros) são combinados e classificados até se obter o melhor índice de classificação. Em (d) as principais características formarão os padrões supervisionados ou banco de dados, o qual será submetido a um método de classificação. Em (e) o arquivo de classificação gerado no pré-processamento na fase (d) será dividido em padrões

supervisionados para uma fase de treinamento (aprendizado) e padrões para a fase de validação e classificação dos dados. Posteriormente, os mesmos serão processados por um classificador (*off-line*) que realizará a classificação de acordo com as classes supervisionadas (RAITZ, 2002; GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011; KHAN *et al.*, 2010).

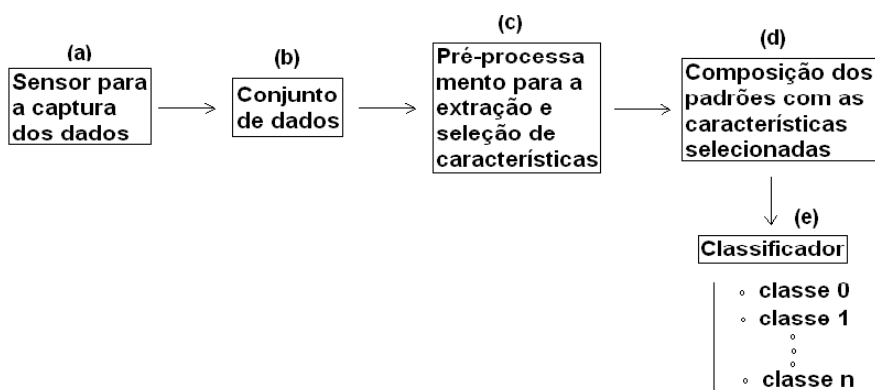


Figura 16 - Diagrama em blocos do procedimento utilizado para o reconhecimento de padrões.
Fonte: Autoria própria.

O objetivo principal do reconhecimento de padrões é a classificação final (RAITZ, 2002). Nos estudos referenciados nesta pesquisa, a seleção das principais características para a detecção e classificação dos movimentos como limiares de amplitude, valores de mínimo e máximo de amplitude, duração ou tempo (de repetição, subida e descida), frequência e valores de *offset* dos sinais capturados, foram utilizados em diversos trabalhos encontrados na literatura recente, como exemplo:

- O cálculo dos pontos que ultrapassam um valor de “limiar” como critério de detecção e classificação de movimentos (CUPPENS *et al.*, 2007; CUPPENS *et al.*, 2009; BURCHFIELD E VENDATESAN, 2007; ELEVANT, 1999; GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011);
- O cálculo da energia dos sinais de entrada para a detecção de crises de epilepsia (CUPPENS *et al.*, 2007; CUPPENS *et al.*, 2009);
- O tempo para o sinal chegar à zero partindo de um ponto de máximo como critério para o acionamento de um alarme (ELEVANT, 1999);

- O cálculo de valores médios de amplitude e uma análise gráfica de espectros de frequência para a avaliação de tremores (WINTER, 1999);
- O cálculo da frequência dos sinais baseada na transformada rápida de Fourier (FFT) e a amplitude média como parâmetros suficientes para auxiliar o médico em avaliações clínicas de tremores (CICHACZEWSKI e CUNHA, 2008).
- O cálculo das distâncias entre os pontos de mínimo e máximo, bem como os tempos percorridos entre os pontos discretizados (GIACOMOSSI E PICHORIM, 2010; GIACOMOSSI *et al.*, 2011);
- O cálculo de áreas de triângulos elaborados no método de Giacomossi e Pichorim (2010);
- O cálculo de área associado à magnitude dos sinais (KHAN *et al.*, 2010);
- O cálculo da inclinação ou ângulos do sinal (NIJSEN, 2008; GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011); e
- O cálculo de valores médios (*offset*) relacionados com mudanças de postura (NIJSEN, 2008; WINTER, 1999; CICHACZEWSKI e CUNHA, 2008).

No próximo capítulo será apresentado o método utilizado no desenvolvimento dos experimentos, tomando como base as principais contribuições encontradas nas referências bibliográficas.

4 MÉTODO DE DESENVOLVIMENTO DA PESQUISA

Como não foram encontrados dados prontos (de outros estudos) para a realização desta pesquisa, estes foram capturados no laboratório Biota da UTFPR considerando voluntários adultos.

4.1 Método de captura dos dados

Um único módulo sensor, baseado no dispositivo integrado eletrônico acelerômetro, foi utilizado para capturar 10 categorias ou classes de movimentos objetos de estudo. Dos dados capturados, armazenados em três arquivos no formato *Comma Separated Values* (CSV) (referentes aos 3 eixos ortogonais x, y e z do acelerômetro), em um pré-processamento foram extraídas características para a composição de padrões (arquivo no formato texto, dividido em um arquivo de padrões para a fase de treinamento e outro para a validação ou classificação dados), os quais foram processados *off-line* por duas arquiteturas de redes neurais para a comparação dos resultados: *Multi-Layer Perceptron* (MLP) e FAN (*Free Associative Neurons*).

Na aquisição dos dados de movimentos normais e anormais de humanos, foram realizados 3 experimentos distintos:

a) Primeiro experimento

- Foram capturados os dados de 5 voluntários adultos, das seguintes categorias de movimentos: andando, correndo, tremores, palmas e aceno de tchau;
- Os movimentos da classe “tremores” (simulados em laboratório) foram orientados por um especialista, o médico Dr. Alfredo Lohr Jr, que é responsável pelo setor de neuropediatria do Hospital Pequeno Príncipe de Curitiba;

- O módulo sensor foi preso no pulso dos voluntários e não houve um controle sobre a realização dos movimentos (amplitude e intensidade dos movimentos);
- A taxa de amostragem na captura dos dados foi de 100 Hz ou 100 pontos discretizados a cada segundo;
- Dez características foram utilizadas na composição dos padrões;
- Foram processados 375 padrões, sendo 250 utilizados no treinamento das redes neurais e 125 na validação e classificação dos mesmos;
- A média dos percentuais de acerto na classificação dos dados foi de 81,6% e 72,6% para as redes neurais FAN e MLP, respectivamente.

b) Segundo experimento

- Foram capturados os dados de um único voluntário adulto, das seguintes categorias de movimentos: andando, correndo, tremores, palmas e aceno de tchau;
- Os movimentos foram controlados ou regulados no momento da execução (amplitude e intensidade dos movimentos);
- O módulo sensor foi preso no pulso do voluntário na realização deste experimento. A única exceção foi à captura do movimento “correndo”, sendo que neste caso, o módulo sensor foi preso no tornozelo para receber com maior intensidade as vibrações de impacto com o chão;
- A taxa de amostragem na captura dos dados foi de 66 Hz ou 100 pontos discretizados a cada 1,515 segundos;
- Dez características foram utilizadas na composição dos padrões;
- Foram processados 2100 padrões, sendo 1500 utilizados no treinamento das redes neurais e 600 na validação e classificação dos mesmos;
- A média dos percentuais de acerto na classificação dos dados foi de 98,2% e 96,7% para as redes neurais FAN e MLP, respectivamente.

c) Terceiro experimento

- Foram capturados os dados de um único voluntário adulto, das seguintes categorias de movimentos: penteando o cabelo, aparafusando, círculos no ar realizados com uma das mãos, socos no ar e coçando a perna. As 5 novas categorias de movimentos, foram adicionadas aos movimentos do segundo experimento para a composição de um único arquivo de dados;
- Os movimentos foram controlados ou regulados no momento da execução (amplitude e intensidade dos movimentos);
- O módulo sensor foi preso no pulso do voluntário para a realização deste experimento;
- A taxa de amostragem na captura dos dados foi de 66 Hz;
- Foram processados 4200 padrões, sendo 3000 utilizados no treinamento das redes neurais e 1200 na validação e classificação dos mesmos. Na composição destes padrões (com 10 características) estão inclusos os dados do segundo experimento. Os resultados da classificação final dos dados apresentaram baixo índice de acerto para alguns dos movimentos objetos de estudo;
- Outro processamento foi realizado gerando 4200 padrões, sendo 3000 utilizados no treinamento das redes neurais e 1200 na validação e classificação dos mesmos. Na composição destes padrões foram inclusas 3 novas características (totalizando 13 características). Foram reprocessados os dados do segundo experimento (com 13 características) e adicionados aos dados deste experimento;
- A média dos percentuais de acerto na classificação dos dados foi de 99,3% e 99,1% para as redes neurais FAN e MLP, respectivamente.

A figura 17 apresenta alguns exemplos de sinais das categorias de movimentos capturados no segundo experimento, os quais correspondem aos mesmos movimentos executados no primeiro experimento, com as denominações: andando, correndo, tremores, batendo palmas e aceno de tchau. Para todos os sinais foi calculado o módulo do vetor aceleração nos três eixos ortogonais. No eixo

horizontal, são apresentadas algumas janelas com 100 pontos discretizados no tempo, com taxa de amostragem alterada para 66 Hz ou 100 pontos a cada 1,515 segundos e no eixo vertical o valor da amplitude em volts correspondente (HIROZAWA *et al.*, 2010; MARTINS *et al.*, 2010).

A figura 18 apresenta alguns exemplos de sinais das categorias de movimentos que foram adicionados ao terceiro experimento, com as denominações: penteando, aparafusando, círculos, socos no ar e coçando a perna. Os movimentos capturados neste experimento foram executados por um único voluntário e adicionados aos dados do segundo experimento, complementando os 10 movimentos objetos de estudo desta pesquisa. É importante observar, que algumas das categorias de movimentos foram executadas em planos diferentes, como os movimentos círculos no ar com um das mãos (na vertical) e aparafusando (na horizontal). Devido à similaridade das características observadas entre essas categorias de movimentos, no terceiro experimento, foram utilizadas três novas características envolvendo parâmetros posturais dos eixos x, y e z do acelerômetro (posição em relação à aceleração da gravidade).

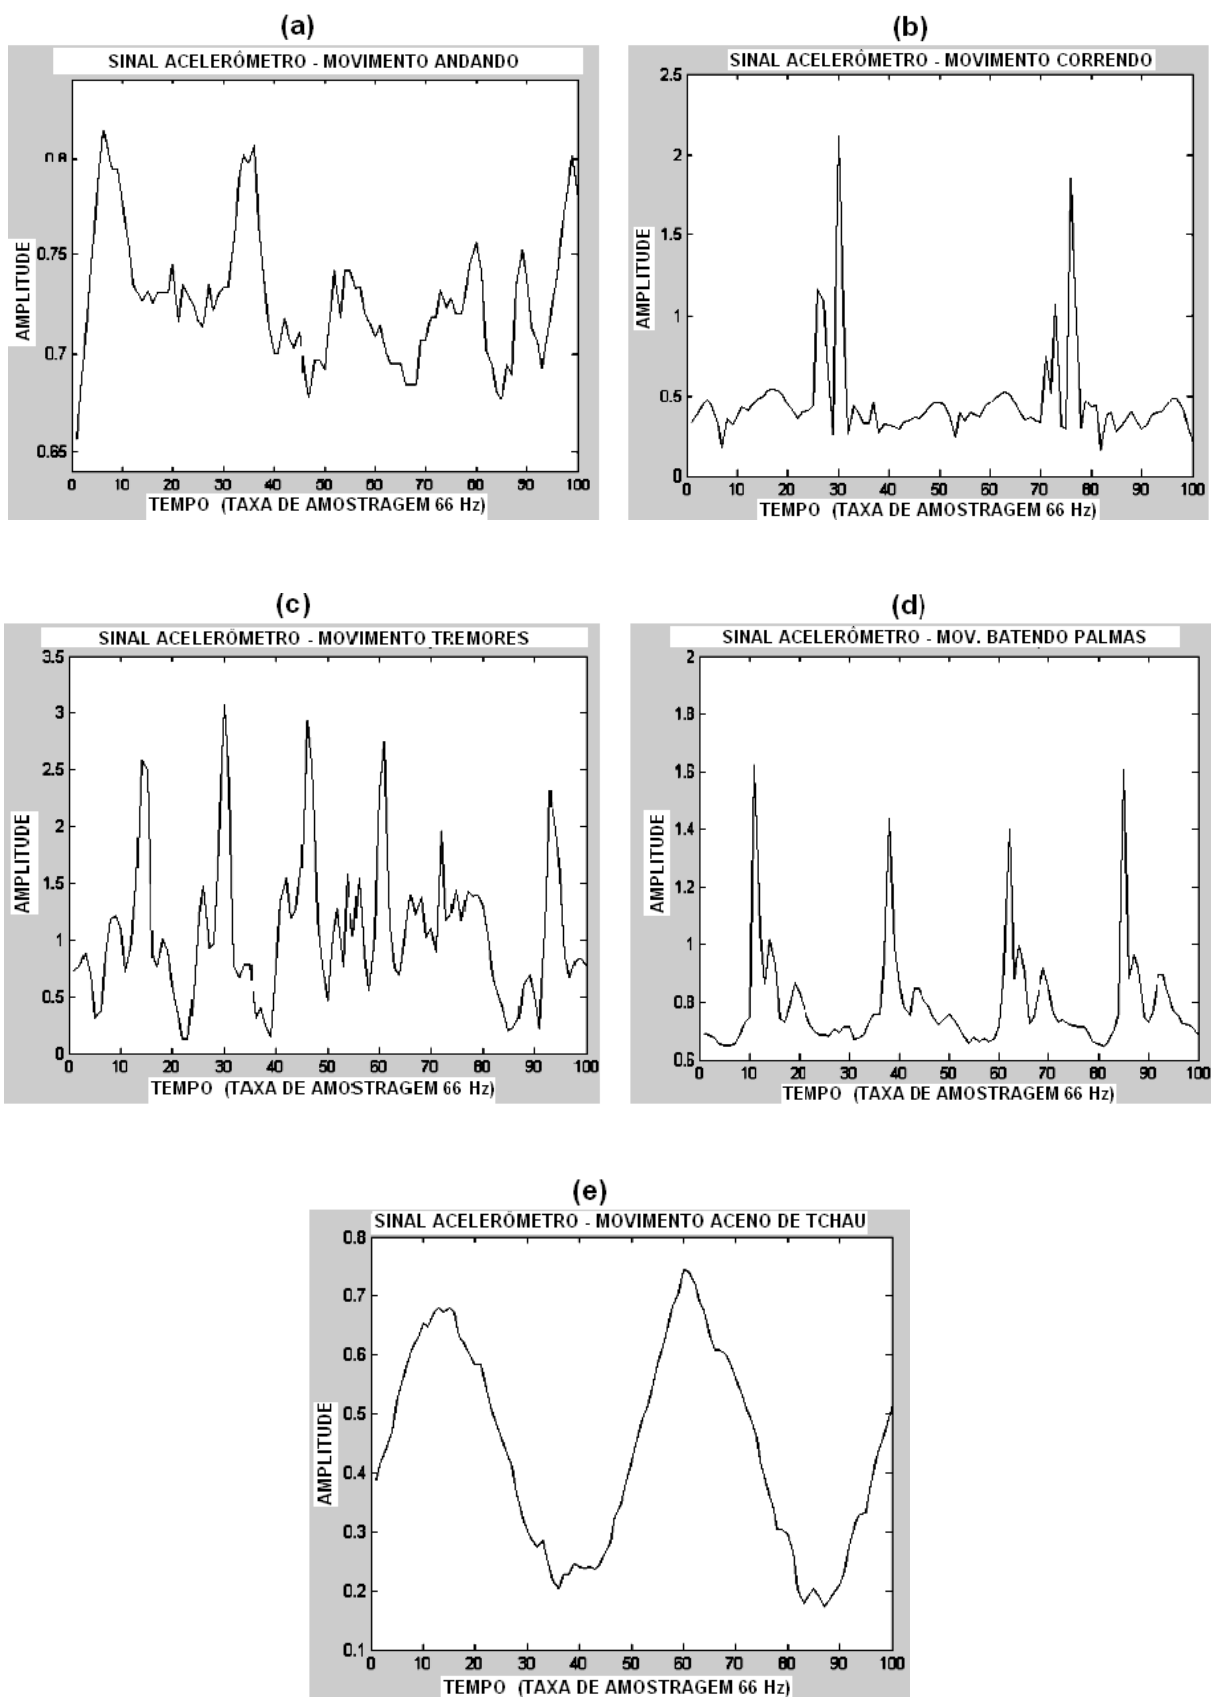


Figura 17 - Os gráficos (a), (b), (c), (d) e (e) são exemplos de algumas janelas com 100 pontos discretizados no tempo, dos sinais correspondentes aos movimentos “andando”, “correndo”, “tremores”, “batendo palmas” e “aceno de tchau”, respectivamente.

Fonte: Autoria própria.

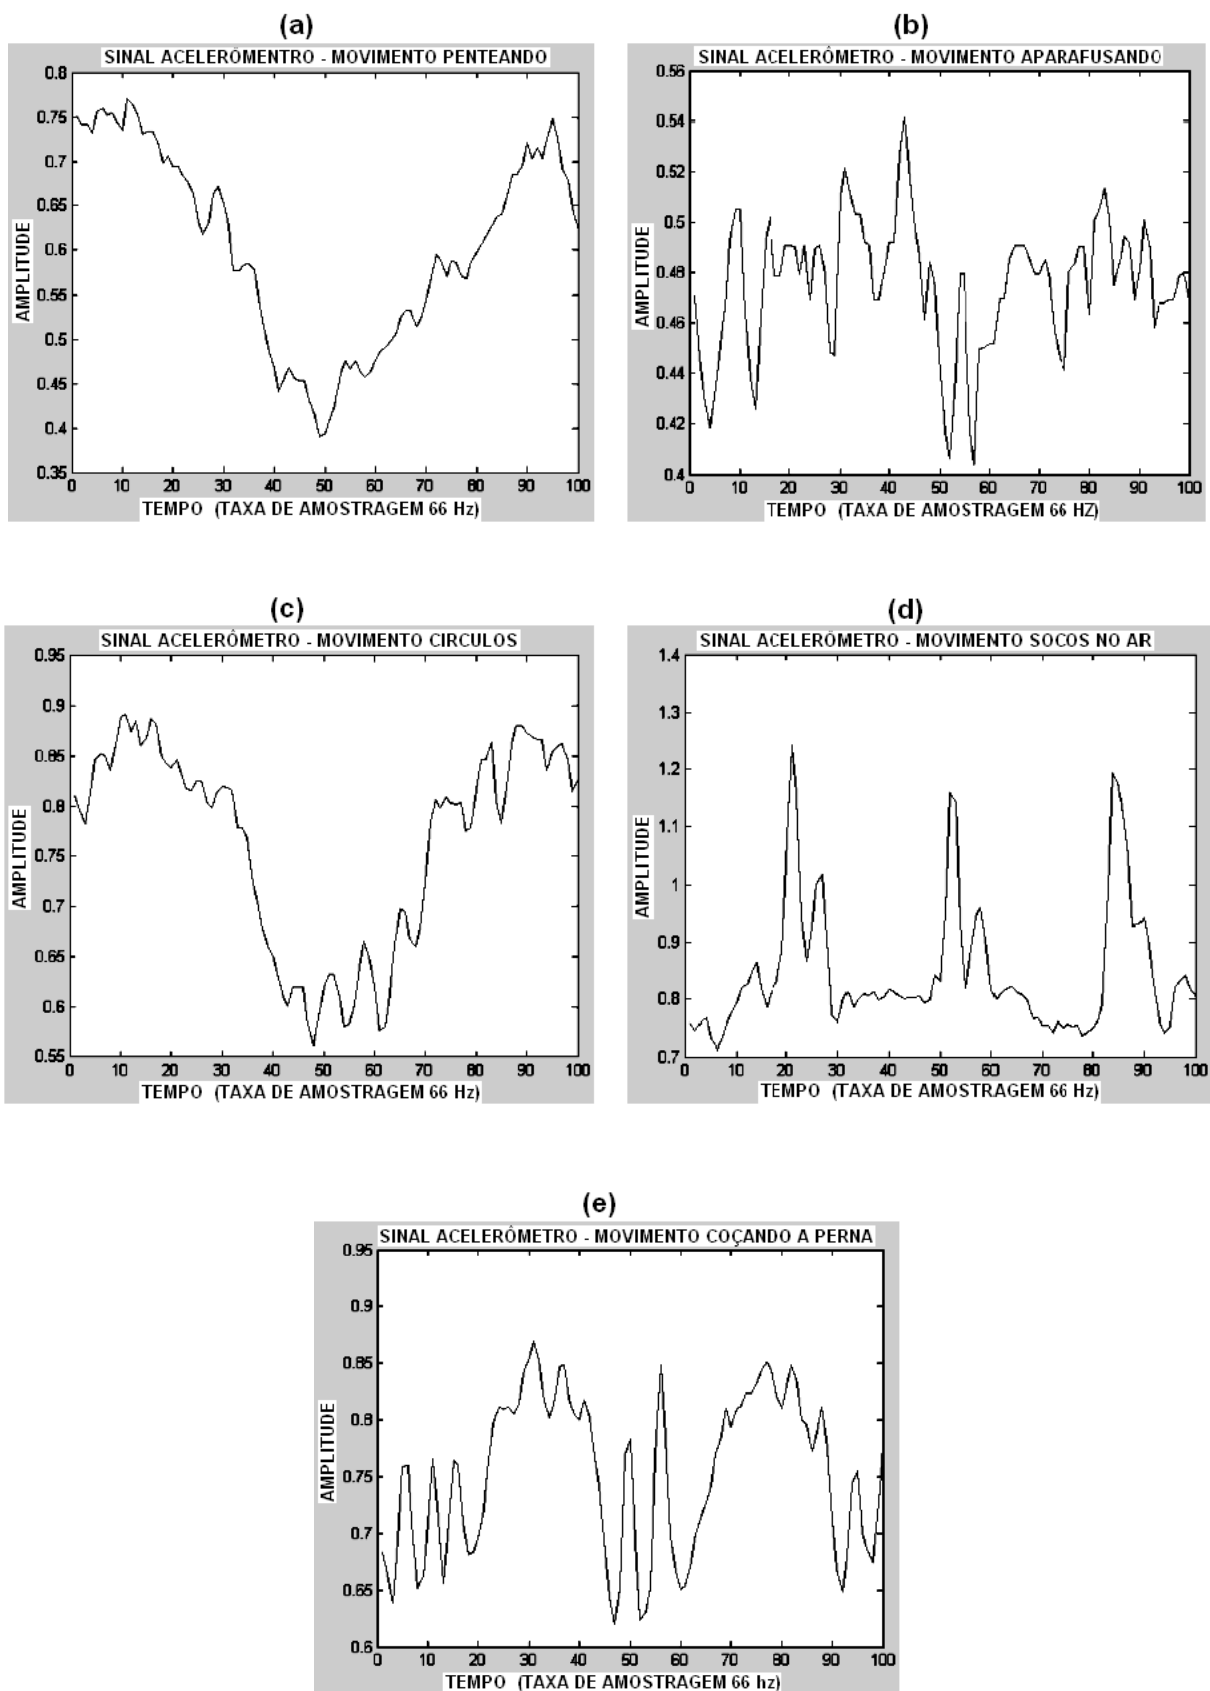


Figura 18 - Os gráficos (a), (b), (c), (d) e (e) são exemplos de algumas janelas com 100 pontos discretizados no tempo, dos sinais correspondentes aos movimentos “penteando”, “aparafusando”, “círculos”, “socos no ar” e “coçando a perna” respectivamente.
 Fonte: Autoria própria.

4.2 Dispositivos de aquisição dos dados

Para a aquisição de dados, foi utilizado o acelerômetro de três eixos modelo MA7260QT da Freescale, que é responsável por coletar dados dos movimentos objetos de estudo através de acelerações produzidos sobre o mesmo nos três eixos ortogonais. O acelerômetro é alimentado com tensão de 3,3 V, a tensão de zero g é de 1,65 V e um ajuste de sensibilidade de 200 mV de acréscimo ou decréscimo para cada g de aceleração. O valor máximo de aceleração para a sensibilidade utilizada é de 6 g , ou seja, de -6 a $+6$ g (BURCHFIELD e VENDATESAN, 2007; FIGUEIREDO *et al.*, 2007; HIROZAWA *et al.*, 2010). A figura 19 mostra a possibilidade de captura dos movimentos de aceleração nos três eixos ortogonais.




Figura 19 - Orientação de aquisição de dados pelo acelerômetro nos três eixos ortogonais.
Fonte: Autoria própria.

O projeto de todo o *hardware* e *software* necessário para a captura dos dados foi realizado por quatro alunos de iniciação científica da UTFPR e teve como início o desenvolvimento de um módulo sensor (HIROZAWA *et al.*, 2010; MARTINS *et al.*, 2010).

O tamanho do sensor deve ser pequeno para não interferir nas medições, além de apresentar baixo consumo e com comunicação *wireless* (sem cabo) (KHAN *et al.*, 2010). Neste estudo, as conexões ainda foram estabelecidas via cabo, mas são leves e flexíveis (GRAHAM, 2000). Alguns testes foram realizados com o cone móvel de um alto-falante ligado a um gerador de sinais para comparar as características do sinal apresentado na captura das vibrações pelo acelerômetro (forma de onda e frequência), comprovando assim o seu correto funcionamento.

A figura 20 apresenta o diagrama em blocos do *hardware* utilizado no primeiro experimento. Em um primeiro momento foram utilizados *jumpers* para conectar as saídas analógicas dos eixos x, y e z do acelerômetro a um osciloscópio digital de quatro canais Agilent modelo DSO5034A, responsável pelo armazenamento dos dados coletados no formato *Comma Separated Values* (CSV). Os arquivos salvos eram transferidos a um PC via *pen drive*/USB para posterior processamento (*off-line*). Os sinais dos três eixos x, y e z do acelerômetro, são condicionados por um filtro com frequência de corte (f_c) de 1 kHz (HIROZAWA *et al.*, 2010).

A figura 21 apresenta os dispositivos de *hardware* e *software* utilizados no segundo e terceiro experimento. Em (a), a placa do módulo sensor é condicionada em uma caixa plástica (38 mm x 60 mm x 13 mm) para isolamento elétrico (evitando o contato com o braço do paciente e um possível choque elétrico) e preza ao pulso de voluntários por uma pulseira de relógio, a qual é conectada ao módulo de comunicação utilizando um cabo serial de 3 metros de comprimento (permitindo a realização de movimentos amplos).

O módulo de comunicação em (a) comunica-se com o PC através de um cabo especial que converte o padrão RS232 para USB. Em (b) mostra placa do módulo sensor (30 mm x 30 mm) e em (c) é apresentada a tela principal de um *software* para a captura e armazenamento dos dados (eixos x, y e z do acelerômetro separadamente) no PC. A nova versão do *hardware* permitiu a captura em tempo real dos dados no PC. No entanto a classificação dos movimentos continua a ser *off-line*.



Figura 20 - Dispositivos utilizados no primeiro experimento para a captura e armazenamento dos dados nos três eixos ortogonais.

Fonte: A autoria própria.

A figura 22 ilustra as alterações efetuadas no módulo sensor e um esquema geral para a captura dos dados. Nesta fase, o módulo sensor em (a) foi alterado para fazer com que o dispositivo circuito integrado acelerômetro transmitisse os

dados de aquisição nos três eixos ortogonais (x, y e z) separadamente para um microcontrolador (circuito integrado modelo PIC 16F886). Este, por sua vez, é dotado de conversores analógico-digital, que convertem os dados analógicos em dados digitais, transferindo-os serialmente (com um cabo de 3 metros) para o bloco responsável pela comunicação como o PC via porta USB. Os sinais dos três eixos x, y e z do acelerômetro, são condicionados por um filtro com frequência de corte (f_c) de 1 kHz (HIROZAWA *et al.*, 2010), no módulo de comunicação. Nos apêndices A e B são apresentados os diagramas esquemáticos completos dos circuitos desenvolvidos.

Foi desenvolvido um *software* (pelos aluno de iniciação científica – ver figura 21) através da plataforma.net, na linguagem C#, que realiza a leitura do sinal capturado pelo sensor acoplado ao microcontrolador conectado à porta serial de um PC. Este possui uma interface gráfica que permite a leitura das informações recebidas pela porta serial, de forma *raw* (como foram recebidas), e a geração de um registro de todos os pacotes recebidos por meio de um arquivo de *log*, salvo no mesmo formato CSV mencionado anteriormente (MARTINS *et al.*, 2010).




Figura 21 - Em (a) mostra a caixa onde o módulo foi condicionado (3,8 cm x 6 cm) presa a um dos pulsos de voluntários por uma pulseira de relógio. Em (b) apresenta a placa do módulo sensor (3cm x 3cm) contendo o acelerômetro (modelo MA7260QT da Freescale) à direita e o microcontrolador (circuito integrado modelo PIC 16F886) à esquerda e em (c) a tela principal do *software* para captura dos dados que são armazenados no PC.
Fonte: Autoria própria.

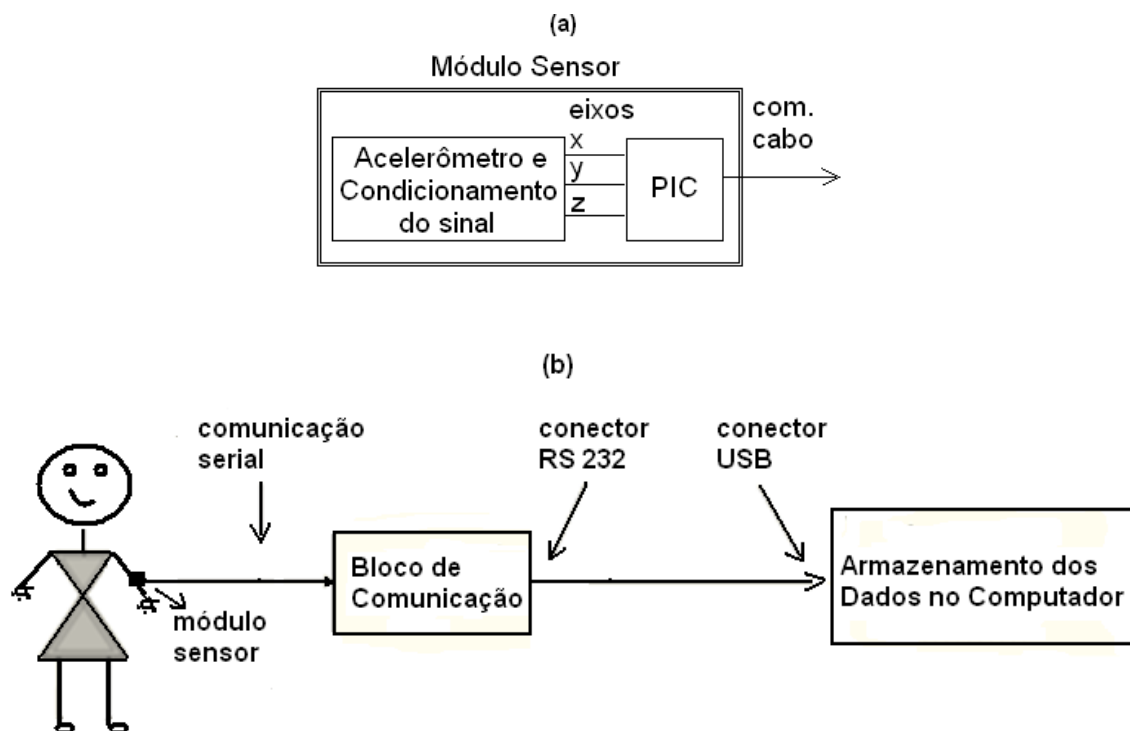


Figura 22 - Em (a), apresenta o projeto simplificado do módulo sensor que foi adaptado ao pulso de voluntários. Em (b), apresenta a aquisição de dados com comunicação serial via cabo até o bloco de comunicação, que por sua vez, estabelece a comunicação com um computador, também via cabo (de um lado no padrão RS232 e do outro padrão USB), onde os dados são gravados para o processamento posterior (*off-line*).

Fonte: A autoria própria.

4.3 Método para obtenção das características

Conforme descrito anteriormente, os dados dos movimentos objetos de estudo foram capturados pelo dispositivo sensor e armazenados em um PC como arquivos em formato texto, um para cada eixo do acelerômetro (x, y e z).

Após a fase de aquisição dos dados, realizada em três experimentos distintos, um pré-processamento elaborado na plataforma Matlab 6.5 calcula as principais características ou parâmetros representativos da amplitude, tempo e frequência dos sinais adquiridos.

A metodologia adotada é baseada no reconhecimento de padrões supervisionados, sendo todas as características elaboradas a cada 100 pontos discretizados (conforme descrito no item 4.1).

Deste ponto em diante, serão apresentados os cálculos de tais características. No entanto, cabe ressaltar que não foram utilizadas características relacionadas a parâmetros posturais estáticas nos dois primeiros experimentos.

Ainda deve-se considerar uma variável j variando de 1 a 100 em todos os cálculos efetuados como índice dos pontos de cada um dos vetores que armazenam os dados dos movimentos objetos de estudo, simplesmente para evitar a repetição desta informação em cada cálculo.

As três primeiras características, denotadas por Mdx , Mdy e Mdz , referem-se a parâmetros posturais ou valores de *offset*, onde são calculadas as médias dos vetores x , y e z (NIJSEN, 2008; CICHACZEWSKI e CUNHA, 2008; WINTER, 1999).

$$Mdx = \sum_{j=1}^{100} x(j)/100, \quad (8)$$

$$Mdy = \sum_{j=1}^{100} y(j)/100, \quad (9)$$

$$Mdz = \sum_{j=1}^{100} z(j)/100. \quad (10)$$

Para as próximas características foi utilizado o cálculo do vetor módulo, $M(j)$, dos vetores x , y e z (CUPPENS *et al.*, 2007; CUPPENS *et al.*, 2009; BURCHFIELD e VENDATESAN, 2007) incorporando em uma única variável a aceleração dos três eixos, de acordo com a fórmula definida na equação (11)

$$M(j) = \sqrt{(x(j))^2 + y(j)^2 + z(j)^2}. \quad (11)$$

A quarta característica é a determinação da freqüência que apresenta a raia de maior amplitude. Isso é obtido a partir da Transformada Rápida de Fourier (FFT) sobre o vetor módulo da aceleração ($M(j)$). A figura 23 ilustra o resultado da FFT na composição de um padrão para o movimento batendo palmas tem na freqüência aproximada de 5,5 Hz, a máxima amplitude (WINTER, 1999; CICHACZEWSKI e CUNHA, 2008).

O próximo passo no desenvolvimento do método é o cálculo de um valor de “limiar” (L), a partir do qual são definidos os pontos com amplitude significativa para a elaboração de um novo sinal (CUPPENS *et al.*, 2007; CUPPENS *et al.*, 2009; BURCHFIELD e VENDATESAN, 2007; ELEVANT, 1999; GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011). O cálculo do valor de “limiar” foi

efetuado com base em um sinal capturado com o módulo sensor colocado no pulso de um voluntário deitado e realizando somente alguns movimentos que normalmente acontecem durante o sono (como virar de lado e coçar a cabeça, entre outros.). Foi realizado o cálculo do módulo dos três eixos do acelerômetro a partir da equação (11) e o resultado foi armazenado no vetor denominado V_{dorm} . Na sequência, foi realizado o cálculo da média do vetor V_{dorm} , que foi armazenada na variável M_{dorm} . Ao valor de M_{dorm} pode ser adicionado ou subtraído um valor de percentual (V_p) da média calculada (M_{dorm}), conforme a equação (12)

$$L = M_{dorm} \pm V_p * M_{dorm} . \quad (12)$$

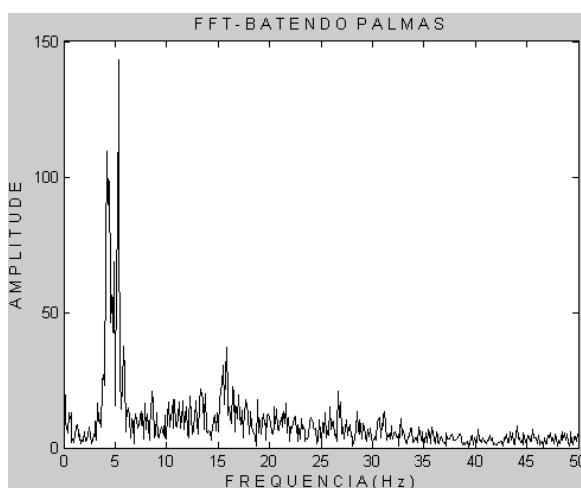


Figura 23 - Gráfico que apresenta a Transformada Rápida de Fourier (FFT) do cálculo de um dos padrões para o movimento batendo palmas.
Fonte: Autoria própria.

O valor de “limiar” serviu como filtro dos pontos de amplitudes não significativas (CUPPENS *et al.*, 2007; CUPPENS *et al.*, 2009; GIACOMOSSI *et al.*, 2011) e foi elaborado neste projeto de modo a poder ser ajustado (como um ajuste de sensibilidade). Devido às diferenças de características apresentadas entre os movimentos estudados, foram utilizados valores de “limiar” distintos para algumas categorias. Os valores calculados para os 10 movimentos objetos de estudo nos experimentos realizados nesta pesquisa são apresentados na tabela 1.

A figura 24 (a) apresenta uma amostra de 100 pontos correspondentes ao movimento penteando, em que é considerado um valor de “limiar” 0,52, o qual foi utilizado nesta categoria de movimento. Na figura 24 (b) pode-se observar que a janela foi alterada apresentando somente os pontos acima do “limiar” (com aproximadamente 80 pontos), ou seja, um novo sinal foi gerado. É importante

observar que o eixo horizontal no gráfico (b) não é mais o “tempo”, com a eliminação das posições do vetor com valor inferior ao valor do “limiar” calculado. Na sequência, foram determinados pontos de mínimo e máximo sobre o sinal da janela (b). Deste ponto em diante, são calculadas retas entre os pontos encontrados como mostra o gráfico (c), formando uma sequência de triângulos. Apesar da janela (c) mostrar apenas quatro triângulos, os referidos cálculos são efetuados para toda a janela (GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011).

Tabela 1 - Valores de “Limiar” Calculados para os 10 Movimentos Objetos de Estudo

Movimentos	Valor de Limiar
Andando	0,52
Correndo	0,28
Tremores	0,52
Palmas	0,52
Aceno de tchau	0,28
Penteando	0,52
Aparafusando	0,40
Círculos	0,52
Socos no ar	0,52
Coçando a perna	0,52

Fonte: Autoria própria.

Neste ponto, deve-se fazer uma consideração importante, lembrando o estudo de Elevant (1999) (descrito no capítulo 3), onde o sinal capturado pelo acelerômetro (em um dos algoritmos apresentados para a detecção de crises de epilepsia) é transformado em um novo sinal. Este sinal contorna os pontos de máximo e na rampa de descida apresenta uma queda linear, procedimento que é contínuo, de modo a gerar um sinal que sempre excede o original. O estudo de Elevant (1999) apresenta parâmetros relevantes, que serviram de base para a elaboração da sequência de triângulos realizada nesta pesquisa. A diferença em relação ao estudo de Elevant (1999) é que, a partir do cálculo dos pontos de máximo, foram determinados pontos de mínimo, e entre esses pontos, o cálculo de retas, tais como: retas de subida (rampa de subida do sinal), retas de descida

(rampa de descida do sinal) e retas de base (base dos triângulos). Um procedimento inovador, que transforma qualquer sinal de entrada em uma sequência de triângulos, os quais apresentam as suas dimensões alteradas proporcionalmente à amplitude, intensidade e frequência dos sinais capturados (GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011).

Na figura 25, os triângulos foram redesenhados, considerando apenas alguns deles, mas o procedimento é realizado para toda a janela da figura 24 (c), realçando as retas de subida, descida e de base dos triângulos, conceitos que serão utilizados na definição das próximas características. Na mesma figura, foram padronizadas as variáveis:

- k como um contador dos pontos calculados de mínimo e máximo (sobre os pontos que ultrapassaram o valor estipulado como “limiar”),
- m o total de pontos gerados,
- i o contador de triângulos e
- n o total de triângulos gerados.

As variáveis k , m , i e n devem ser consideradas nos cálculos das próximas características.

A quinta característica elaborada refere-se ao cálculo da soma das áreas dos triângulos (SA) definidos na etapa anterior de processamento (KHAN *et al.*, 2010; GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011). A área de cada triângulo é atribuída à variável AT na equação (13) e SA acumula a somatória destas áreas conforme a equação (14).

Para $k=1$ até m ,

$$AT = \frac{1}{2} \begin{vmatrix} x_k & y_k & 1 \\ x_{k+1} & y_{k+1} & 1 \\ x_{k+2} & y_{k+2} & 1 \end{vmatrix} \quad (13)$$

$$SA = \sum_{i=1}^n AT(i), \quad (14)$$

Na figura 25, as coordenadas (x_k, y_k) , (x_{k+1}, y_{k+1}) e (x_{k+2}, y_{k+2}) correspondem aos vértices de cada um dos triângulos, os valores de x à amplitude do sinal e os valores de y , os tempos da figura 24 (a), correspondentes aos pontos de amplitude

acima do “limiar”, os quais são armazenados em um vetor tempo (com os valores de tempo na figura 24 (b) descontinuados).

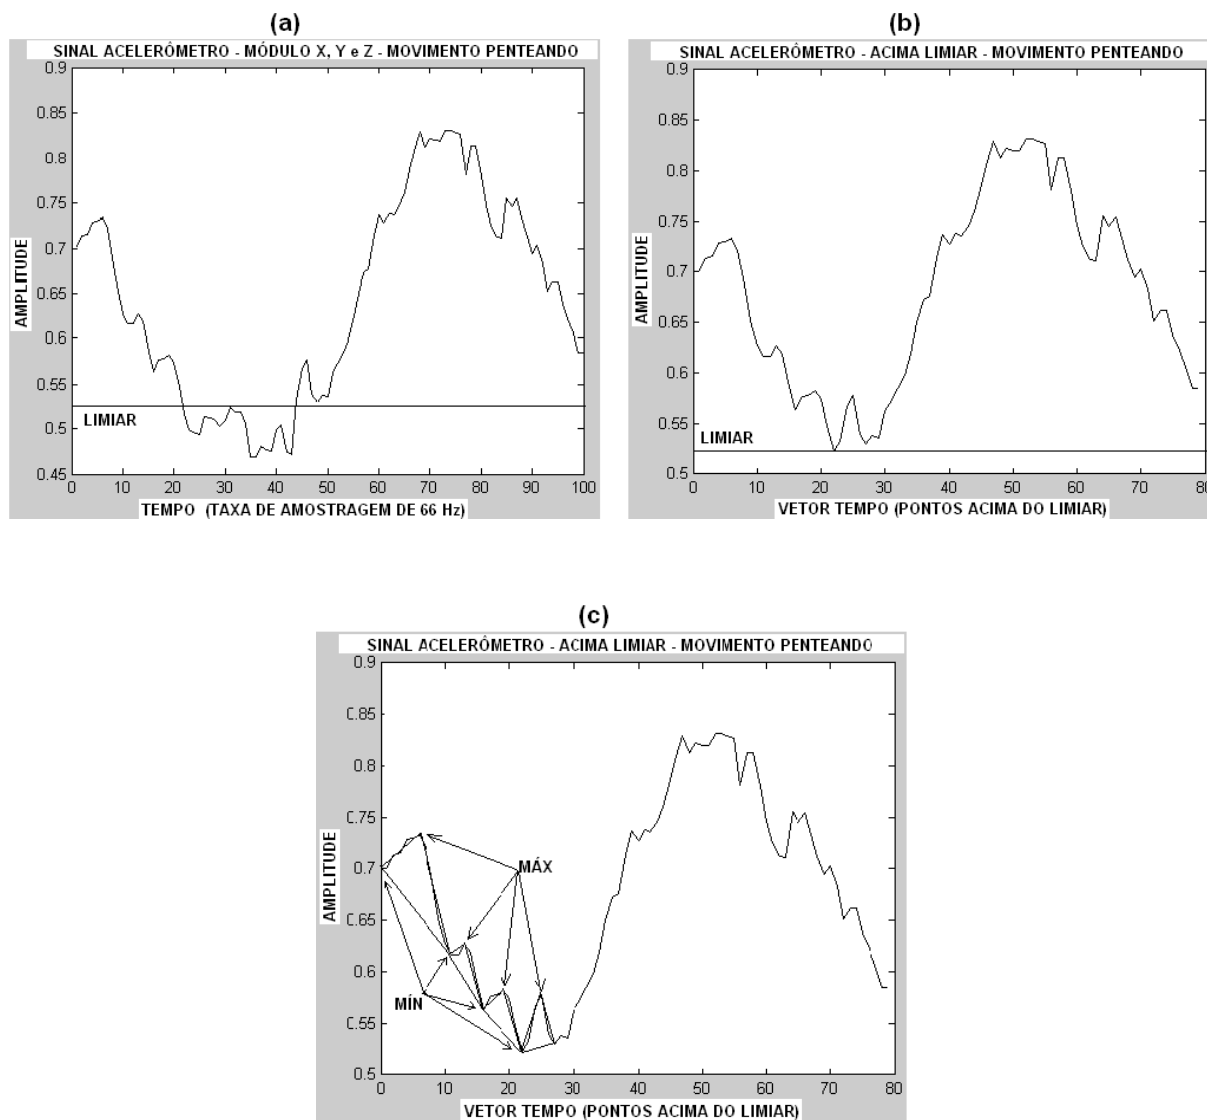


Figura 24 - O gráfico (a) mostra o sinal capturado pelo acelerômetro do movimento penteando com o valor de "limiar" calculado em aproximadamente 0,52. No gráfico (b) são apresentados somente os pontos acima do “limiar” baseado na janela anterior. O gráfico (c) mostra os pontos de mínimo e de máximo (considerar para toda a janela) encontrados e as retas calculadas entre esses pontos, formando uma sequência de triângulos.

Fonte: Autoria própria.

A média das rampas de subida do sinal (MS), ou seja, das i distâncias (Sub) entre as k coordenadas de mínimo e máximo da rampa de subida do sinal, considerando os n triângulos gerados, corresponde à sexta característica (GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011), é definida como segue

$$MS = \frac{1}{n} \sum_{i=1}^n Sub(i) \quad (15)$$

$$Sub = \sqrt{(x_k - x_{k+1})^2 + (y_k - y_{k+1})^2}. \quad (16)$$

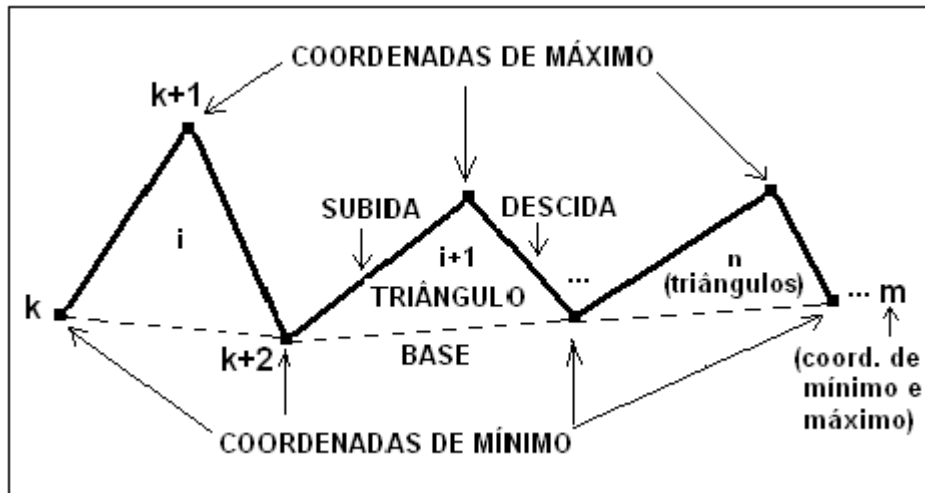


Figura 25 - Mostra a variável k que é o contador do número de pontos calculados de mínimo e máximo (sobre os pontos que ultrapassaram o valor estipulado como “limiar”), m o total de pontos gerados, i o contador de triângulos e n o total de triângulos gerados. As retas de “subida”, “descida” e “base” calculadas entre os pontos de mínimo e máximo, formando uma sequência de triângulos irregulares.

Fonte: Autoria própria.

A média das rampas de descida do sinal (MD) corresponde à sétima característica, ou seja, das i distâncias (Des) entre as k coordenadas de máximo e mínimo da rampa descida do sinal, para os n triângulos gerados, conforme os cálculos (GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011),

$$MD = \frac{1}{n} \sum_{i=1}^n Des(i) \quad (17)$$

$$Des = \sqrt{(x_{k+1} - x_{k+2})^2 + (y_{k+1} - y_{k+2})^2}. \quad (18)$$

A oitava característica corresponde à média das retas de base (MB) ou das i bases (Bas) para os n triângulos gerados com o novo sinal (GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011), como segue,

$$MB = \frac{1}{n} \sum_{i=1}^n Bas(i) \quad (19)$$

onde $k=1$ até m ,

$$Bas = \sqrt{(x_k - x_{k+2})^2 + (y_k - y_{k+2})^2}. \quad (20)$$

A média dos perímetros (MP) dos n triângulos gerados, corresponde à nona característica (GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011), conforme os cálculos,

$$MP = \frac{1}{n} \sum_{i=1}^n (Des(i) + Sub(i) + Bas(i)). \quad (21)$$

A média do maior lado dos triângulos corresponde à décima característica e é calculada de maneira similar às outras médias.

A décima primeira característica, denominada de α foi calculada como a média das i distâncias das rampas de subida, dividida pelo intervalo de tempo de subida da rampa, para os n triângulos gerados (GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011), onde k varia de 1 até m , de acordo com a fórmula

$$\alpha = \frac{1}{n} \sum_{i=1}^n (Sub(i)/(y_k - y_{k+1})). \quad (22)$$

O cálculo da média das i distâncias das rampas de subida, dividida pelo intervalo de tempo de subida da rampa elevado ao quadrado, define a décima segunda característica, denominada de β , onde k varia de 1 até m , como segue

$$\beta = \frac{1}{n} \sum_{i=1}^n (Sub(i)/(y_{k+1} - y_{k+2})^2). \quad (23)$$

A décima terceira característica utilizada na formação dos padrões está relacionada com o cálculo da média dos i ângulos de subida dos n triângulos gerados (NIJSEN, 2008; GIACOMOSSI e PICHORIM, 2010; GIACOMOSSI *et al.*, 2011) e foi denominada de θ , onde k varia de 1 até m , de acordo com a fórmula

$$\theta = \frac{1}{n} \sum_{i=1}^n (arc\ tag((x_k - x_{k+1})/(y_k - y_{k+1}))). \quad (24)$$

As características foram calculadas utilizando um programa desenvolvido na plataforma Matlab 6.5 e armazenadas em arquivos texto (.txt) na forma de uma matriz de dados (para a classificação *off-line* dos movimentos estudados), onde as colunas correspondem às características e as linhas aos padrões elaborados a cada 100 pontos discretizados. Conforme exposto anteriormente (ver item 4.1), nos dois primeiros experimentos foram utilizadas 10 características e no último experimento um total de 13 características (inclui todos os cálculos demonstrados anteriormente).

A figura 26 mostra alguns exemplos de padrões supervisionados (somente quatro padrões de cada classe) elaborados no terceiro experimento com 13

características. As características apresentadas são: Transformada Rápida de Fourier (FFT), soma das áreas dos triângulos (SA), média dos perímetros dos triângulos (MP), média das bases dos triângulos (MB), média da rampa de descida do sinal (MD), média da rampa de subida do sinal (MS), média do maior lado dos triângulos (Méd.>.Lado), Alfa (α), Beta (β), Teta (θ), média do eixo x (Mdx), média do eixo y (Mdy), média do eixo z (Mdz) a cada 100 pontos discretizados e na última coluna a “classe” correspondente a cada um dos padrões supervisionados de acordo com a tabela 2. O arquivo texto gerado no Matlab foi dividido em aproximadamente 70% dos padrões para o treinamento da rede neural e 30% destes para a validação e classificação final dos dados em todos os experimentos. É importante ressaltar, que os padrões utilizados na fase de treinamento da rede neural não foram utilizados na validação e classificação final.

A meta é classificar os movimentos objetos de estudo utilizando-se de duas arquiteturas de redes neurais para comparar os resultados: *Multi-Layer Perceptron* (MLP) e *Free Associative Neurons* (FAN).

Na classificação com a rede neural MLP foi utilizado o *software* Matlab com os recursos de Toolboxes, onde foram realizados ajustes na ferramenta Nntool, utilizando-se das funções “newff” e “train” para o treinamento e classificação dos dados gerados. A função de ativação tangente hiperbólica sigmóide “tansig” foi configurada como parâmetro *default* em todas as camadas de neurônios (entrada, ocultas e saída), bem como a taxa de aprendizagem (RAITTZ, 2002). O programa foi executado várias vezes em cada um dos experimentos, até encontrar os valores ideais para o número de neurônios nas camadas de entrada, intermediárias e saída, de modo a obter os melhores índices na classificação final dos movimentos objetos de estudo, conforme a tabela 3. O número de neurônios na camada de entrada corresponde ao número de características, as camadas intermediárias (ocultas) com a capacidade de aprendizado (generalização) e a camada de saídas com o número de classes utilizadas na classificação final.

Para a classificação com a rede neural FAN foi utilizado o programa *easyfan* (KUSTER *et al.*, 2006). A rede neural FAN apresenta arquitetura com abordagem *neuro-fuzzy*, associando um neurônio para cada “classe” ou tipo de movimento objeto de estudo, ou seja, no primeiro experimento e segundo experimento foram utilizados 5 neurônios e no terceiro experimento 10 neurônios. O algoritmo de aprendizado da rede neural FAN utiliza o resultado da comparação e interseção

(correlações) entre as características dos padrões supervisionados aplicando o conceito de “reforço” quando a classificação é correta e “penalização” quando a classificação é incorreta. Para cada valor de uma característica, são calculados valores vizinhos com projeções difusas no espaço FAN, baseada em uma função de pertinência triangular, assumindo valores no intervalo entre 0 e 1.

Tabela 2 - Classes Correspondentes aos 10 Movimentos Objetos de Estudo

Movimentos	Classe
Andando	0
Correndo	1
Tremores	2
Palmas	3
Aceno de tchau	4
Penteando	5
Aparafusando	6
Círculos	7
Socos no ar	8
Coçando a perna	9

Fonte: Autoria própria.

Tabela 3 - N° de Neurônios Utilizados nas Camadas da Rede Neural MLP nos 3 Experimentos

Experimento	Entrada	1ª Oculta	2ª Oculta	Saída
1º	10	7	5	5
2º	10	7	8	5
3º	13	8	6	10

Fonte: Autoria própria.

FFT	SA	MP	MB	MD	MS	Méd.>.Lad	Alfa	Beta	Teta	Mdx	Mdy	Mdz	Classe
2.64	0.02	0.19	0.09	0.04	0.06	0.09	1.24	34.56	30.62	0.27	0.63	0.25	0
1.32	0.03	0.23	0.10	0.06	0.07	0.10	1.48	42.21	40.12	0.25	0.64	0.24	0
3.30	0.03	0.23	0.10	0.06	0.07	0.10	1.44	39.86	39.53	0.24	0.64	0.24	0
3.30	0.03	0.37	0.16	0.09	0.11	0.17	1.52	31.73	39.66	0.24	0.64	0.25	0
2.64	0.02	0.53	0.25	0.11	0.18	0.26	4.97	149.13	58.25	0.23	0.20	0.29	1
2.64	0.04	0.65	0.29	0.17	0.18	0.32	3.92	102.58	54.02	0.20	0.21	0.30	1
5.94	0.07	1.43	0.58	0.42	0.43	0.70	19.11	990.10	57.72	0.20	0.21	0.29	1
2.64	0.04	0.64	0.24	0.24	0.16	0.31	3.69	83.99	57.68	0.22	0.23	0.30	1
11.22	0.42	2.28	0.61	0.81	0.86	1.13	27.34	1239.16	84.39	0.76	0.39	0.34	2
5.28	0.29	1.67	0.46	0.60	0.61	0.83	19.33	776.14	85.47	0.67	0.48	0.46	2
9.24	0.30	2.46	0.93	0.75	0.78	1.22	19.19	528.35	78.36	0.57	0.41	0.49	2
7.26	0.27	1.68	0.51	0.56	0.61	0.84	18.08	566.51	79.98	0.63	0.39	0.38	2
2.64	0.15	1.04	0.44	0.30	0.30	0.50	10.22	527.45	60.86	0.49	0.49	0.31	3
2.64	0.27	1.26	0.53	0.34	0.39	0.62	8.47	201.11	60.17	0.48	0.50	0.33	3
2.64	0.13	0.78	0.28	0.26	0.24	0.38	6.76	260.73	69.49	0.48	0.50	0.30	3
2.64	0.31	1.30	0.52	0.37	0.42	0.64	7.28	153.90	56.60	0.48	0.49	0.33	3
1.32	0.04	0.77	0.32	0.17	0.28	0.33	2.18	17.52	62.73	0.31	0.07	0.17	4
1.32	0.04	0.53	0.21	0.12	0.20	0.21	1.85	18.72	52.90	0.31	0.07	0.17	4
1.32	0.05	0.83	0.34	0.18	0.31	0.34	1.96	12.37	59.38	0.32	0.07	0.18	4
1.32	0.03	0.41	0.17	0.09	0.15	0.17	1.76	25.14	43.79	0.32	0.07	0.18	4
0.66	0.01	0.28	0.12	0.08	0.08	0.13	1.61	50.39	42.37	0.08	0.41	0.43	5
0.66	0.01	0.27	0.12	0.06	0.09	0.12	1.22	38.07	31.19	0.10	0.40	0.44	5
0.66	0.04	0.52	0.21	0.13	0.18	0.23	2.75	59.55	63.86	0.10	0.34	0.45	5
0.66	0.01	0.18	0.08	0.04	0.06	0.08	1.48	51.86	43.10	0.07	0.34	0.44	5
3.30	0.02	0.30	0.13	0.09	0.08	0.14	1.76	40.20	40.83	0.27	0.04	0.32	6
3.30	0.02	0.31	0.14	0.08	0.09	0.15	2.32	68.93	48.13	0.30	0.05	0.27	6
3.30	0.03	0.25	0.10	0.07	0.08	0.10	1.78	60.71	46.89	0.28	0.05	0.31	6
3.96	0.02	0.23	0.09	0.07	0.08	0.10	2.02	71.92	49.99	0.28	0.05	0.30	6
0.66	0.01	0.28	0.14	0.07	0.08	0.14	1.37	30.91	31.87	0.42	0.45	0.43	7
0.66	0.01	0.22	0.11	0.07	0.05	0.11	1.39	46.37	36.27	0.49	0.44	0.46	7
0.66	0.02	0.33	0.15	0.08	0.09	0.15	1.35	26.78	37.99	0.43	0.43	0.50	7
0.66	0.01	0.30	0.14	0.07	0.08	0.14	1.29	35.93	30.19	0.42	0.45	0.44	7
1.98	0.11	0.77	0.33	0.23	0.22	0.38	5.42	147.68	57.01	0.38	0.45	0.51	8
1.98	0.12	0.81	0.36	0.27	0.19	0.40	4.32	98.70	37.79	0.39	0.44	0.53	8
1.98	0.11	0.81	0.35	0.21	0.25	0.40	6.41	172.60	51.24	0.45	0.45	0.49	8
1.98	0.13	0.64	0.26	0.17	0.21	0.31	4.75	118.17	55.63	0.43	0.43	0.52	8
1.32	0.02	0.27	0.12	0.06	0.08	0.13	1.71	55.17	38.42	0.42	0.27	0.57	9
1.32	0.05	0.33	0.13	0.10	0.11	0.15	2.00	46.24	48.10	0.40	0.31	0.58	9
1.32	0.05	0.29	0.11	0.08	0.11	0.13	2.16	66.90	55.19	0.41	0.27	0.58	9
1.32	0.02	0.27	0.12	0.07	0.08	0.13	1.46	45.75	38.73	0.41	0.29	0.58	9

Figura 26 - Mostra as treze características que formam os padrões calculados no desenvolvimento do método e a última coluna como sendo a “classe” a que pertence cada um dos padrões supervisionados.

Fonte: Autoria própria.

Os percentuais de classificação obtidos nos três experimentos realizados no laboratório Biota/UTFPR são apresentados no próximo capítulo em resultados.

5 RESULTADOS

Conforme exposto na metodologia (item 4.1), foram realizados 3 experimentos durante o desenvolvimento deste projeto. No primeiro experimento, o processamento *off-line* que gera um arquivo contendo os padrões supervisionados (com 10 características) elaborou um total de 375 padrões, dos quais 250 (50 de cada movimento e 10 de cada voluntário) para a fase de treinamento e 125 (25 de cada movimento e 5 de cada voluntário) para a validação dos dados. Os percentuais de acerto na classificação final dos 5 movimentos (andando, correndo, tremores, palmas e aceno de tchau) para as duas redes neurais são apresentados na tabela 4 e gráfico 1.

No segundo experimento, as mesmas categorias de movimentos foram executadas por um único indivíduo objetivando a comparação com o primeiro experimento. No processamento (*off-line*) que elaborou um arquivo contendo os padrões supervisionados (com 10 características) foi gerado um total de 2100 padrões, dos quais 1500 (300 de cada movimento) para a fase de treinamento e 600 (120 de cada movimento) para a validação dos dados. Os percentuais de acerto na classificação final de todos os movimentos para as duas redes neurais são apresentados na tabela 5 e gráfico 2.

No terceiro experimento, foram incluídos mais 5 tipos de movimentos realizados por um voluntário (mesmo do experimento 2): penteando, aparafusando, círculos, socos no ar e coçando a perna. Um arquivo com um total de 4200 padrões supervisionados foi gerado, sendo que os dados do segundo experimento foram incluídos aos dados do terceiro experimento (com 10 características ou sem as características posturais), dos quais 3000 (300 de cada movimento) para a fase de treinamento e 1200 (120 de cada movimento) para a validação dos dados. Os percentuais de acerto na classificação final dos padrões, incluindo dados dos 10 movimentos objetos de estudo para a rede neural FAN, são apresentados em uma matriz de confusão na figura 27. Para obter o percentual de acerto para a “classe 0” por exemplo (ver na tabela 2 a correspondência dos números das classes com a denominação dos movimentos), deve-se ler o resultado da interseção da linha e coluna para a referida classe. Os outros valores apresentados na mesma linha da

“classe 0”, correspondem aos percentuais de erro ou as classes para as quais os dados foram identificadas (a classe é indicada na colunas). Neste processamento, os resultados em termos de percentuais de acerto para os movimentos “penteando o cabelo” (classe 5) foi de 38%, “círculos no ar com uma da mãos” (classe 7) com 36,7%, “socos no ar” (classe 8) com 55% e “coçando a perna” (classe 9) com 32,5%, ficaram abaixo do esperado.

A partir deste momento, três novas características ou características posturais foram adicionadas ao método desenvolvido nesta pesquisa. Um novo processamento foi realizado e outro arquivo texto foi gerado no Matlab. Foram reprocessados os dados do segundo experimento para as 13 características e adicionado aos padrões do processamento efetuado no terceiro experimento (também com as 13 características). De um total de 4200 padrões supervisionados, dos quais 3000 (300 de cada movimento) para a fase de treinamento e 1200 (120 de cada movimento) para a validação dos dados. Os percentuais de acerto na classificação final de todos os movimentos para as duas redes neurais são apresentados na tabela 6 e gráfico 3.

	0	1	2	3	4	5	6	7	8	9
0	76.6667%	0.8333%	0.0000%	0.0000%	0.0000%	2.5000%	0.0000%	7.5000%	0.8333%	11.6667%
1	0.0000%	72.5000%	0.8333%	18.3333%	1.6667%	0.0000%	0.0000%	0.0000%	0.0000%	6.6667%
2	0.0000%	0.0000%	94.1667%	4.1667%	1.6667%	0.0000%	0.0000%	0.0000%	0.0000%	0.0000%
3	0.0000%	9.1667%	1.6667%	89.1667%	0.0000%	0.0000%	0.0000%	0.0000%	0.0000%	0.0000%
4	0.0000%	8.3333%	1.6667%	7.5000%	65.8333%	0.8333%	0.0000%	0.0000%	4.1667%	11.6667%
5	21.6667%	2.5000%	0.0000%	0.0000%	1.6667%	38.3333%	0.0000%	16.6667%	1.6667%	17.5000%
6	0.0000%	0.0000%	0.0000%	0.0000%	0.0000%	0.0000%	83.3333%	16.6667%	0.0000%	0.0000%
7	17.5000%	4.1667%	0.0000%	0.0000%	5.0000%	20.8333%	0.0000%	36.6667%	0.8333%	15.0000%
8	3.3333%	8.3333%	0.0000%	0.8333%	1.6667%	5.8333%	0.0000%	3.3333%	55.0000%	21.6667%
9	13.3333%	1.6667%	0.0000%	0.0000%	1.6667%	7.5000%	0.0000%	8.3333%	35.0000%	32.5000%

Quantidade de Ocorrências
 Porcentagem

Média Harmônica da Época: 64.41667175292969
 Máximo do Mínimo da Época: 32.5
 Média Aritmética da Época: 64.41667175292969

Sair

Figura 27 - Matriz de confusão do processamento com a rede neural FAN dos padrões extraídos no terceiro experimento com 10 características (sem as características posturais).
 Fonte: Autoria própria.

Tabela 4 - Resultados Obtidos na Classificação dos Movimentos Realizados por 5 Voluntários

Movimentos	% de acerto p/ FAN	% de acerto p/ MLP
Andando	92	96
Correndo	80	95
Tremores	100	66
Palmas	72	61
Aceno de Tchau	64	45
Média	81,6	72,6

Fonte: Autoria própria.




Gráfico 1 - Resultados obtidos no primeiro experimento, envolvendo 5 voluntários adultos e 5 movimentos diferentes.

Fonte: Autoria própria.

Tabela 5 - Resultados Obtidos na Classificação de 5 Movimentos Realizados por 1 Voluntário

Movimentos	% de acerto p/ FAN	% de acerto p/ MLP
Andando	98,3	100
Correndo	97,5	98,3
Tremores	99,2	90,2
Palmas	95,8	95,6
Aceno de Tchau	100	100
Média	98,2	96,7

Fonte: Autoria própria.

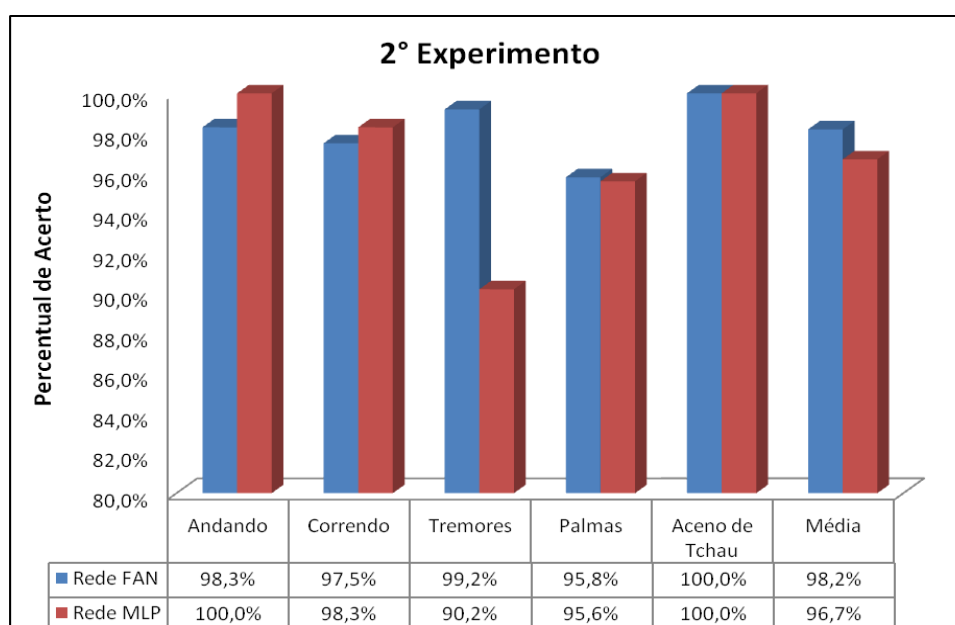


Gráfico 2 - Resultados obtidos no segundo experimento, envolvendo 1 voluntário adulto e 5 movimentos diferentes.

Fonte: Autoria própria.

Tabela 6 - Resultados Obtidos na Classificação de 10 Movimentos Realizados por 1 Voluntário

Movimentos	% de acerto p/ FAN	% de acerto p/ MLP
Andando	100	100
Correndo	100	100
Tremores	100	100
Palmas	97,5	98,3
Aceno de tchau	100	98,3
Penteando	100	97,6
Aparafusando	100	97,6
Círculos	98,3	99,2
Socos no ar	99,2	100
Coçando a perna	98,3	100
Média	99,3	99,1

Fonte: Autoria própria.

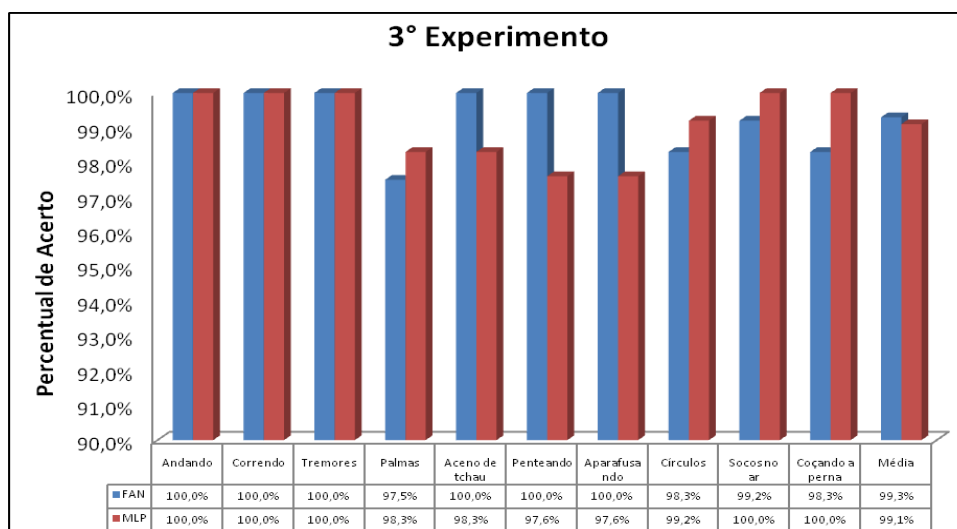


Gráfico 3 - Resultados obtidos no terceiro experimento, envolvendo 1 voluntário adulto e 10 movimentos diferentes.

Fonte: Autoria própria.

6 DISCUSSÕES E CONCLUSÕES

6.1 DISCUSSÕES

Este estudo foi inicialmente vinculado ao Hospital Pequeno Príncipe, tendo sido apresentado um projeto ao comitê de ética. No entanto, após a aprovação do comitê de ética do hospital, houve a solicitação automática do projeto pela Comissão Nacional de Ética em Pesquisa (CONEP). Tendo em vista os prazos de conclusão desta pesquisa e a demora de liberação para a aquisição de dados de pacientes epiléticos (classe “tremores”) pelo CONEP, esses dados não puderam ser capturados, sendo substituídos por simulações orientadas por um profissional da área médica. Isto, no entanto não inviabiliza a eficiência do método e dos experimentos.

É importante observar, que o Hospital Pequeno Príncipe não pode fornecer a carta de aprovação da pesquisa para a aquisição de dados dos pacientes epiléticos, enquanto não houver a liberação desta pelo CONEP. As alterações já foram realizadas e reenviadas para o CONEP, sendo que, em estudos futuros após esta liberação, serão coletados os referidos dados para realizar uma nova classificação com dados reais de “tremores”.

Difícilmente um equipamento baseado no dispositivo integrado eletrônico acelerômetro substituirá os tradicionais exames de EEG (eletroencefalograma), mas podem auxiliar na detecção, classificação e monitoramento de patologias que apresentam distúrbios de movimentos e servir como um elemento coadjuvante nas investigações.

O conceito de um tempo mínimo de repetição dos movimentos em Burchfield e Vendatesan (2007), não foi aplicado na presente pesquisa devido aos critérios diferenciados adotados nos experimentos, onde os movimentos são classificados considerando tempos proporcionais ou iguais para todos os movimentos capturados. Este parâmetro pode ser utilizado em estudos futuros no monitoramento à distância como um fator importante na eliminação de falsos positivos na detecção de eventos (movimentos anormais) com pacientes portadores de patologias graves. Ocorre que os movimentos normais dificilmente são repetidos ininterruptamente, por isso a

adoção de um tempo mínimo de repetição dos mesmos pode ser uma solução viável.

O estudo de Mathie *et al.* (2004) também cita outros métodos como possíveis classificadores, entre eles as regras heurísticas, lógica *fuzzy* e as cadeias de Markov, sem testar essas possibilidades. Em Khan *et al.* (2010) além do emprego de redes neurais na classificação dos dados, outros métodos de classificação foram testados como árvores de decisão, redes Bayesianas e as cadeias de Markov, sendo que os resultados apontaram as redes neurais com os melhores índices de acerto.

As redes neurais foram utilizadas nesta pesquisa tendo em vista os resultados obtidos nos estudos de Khan *et al.* (2010), Nijssen (2008) e outros.

Atualmente, os acelerômetros estão presentes em muitos equipamentos eletrônicos como passômetro (pedômetro), telefones celulares, tablet (orientação de câmeras) e provavelmente farão parte do dia a dia de muitas pessoas. Principalmente no caso das pessoas idosas, que podem ser monitorados em suas atividades diárias e em suas casas, dispensando internamentos e custos desnecessários além da obtenção de um banco de dados mais completo (armazenado *on-line* ou *off-line*) melhorando o diagnóstico e em consequência o tratamento (KHAN *et al.*, 2010).

6.2 CONCLUSÕES

Como não foram encontrados dados prontos (de outros estudos), houve a necessidade do desenvolvimento de um *hardware* que compreende um módulo sensor para a captura dos dados e um módulo de comunicação para a gravação de um arquivo via cabo no PC. Os alunos de iniciação científica da UTFPR desenvolveram esta etapa do projeto, que apresentou grande eficiência na aquisição dos 10 tipos de movimentos objetos de estudo.

Nesta pesquisa, pode-se concluir que o acelerômetro modelo MA7260QT, componente integrado eletrônico, respondeu eficientemente a captura de alguns movimentos mais intensos como batendo palmas, correndo, aceno de tchau (movimentos do cotidiano) e algumas simulações de contrações musculares ou

espasmos convulsivos, correspondentes a classe “tremores” (movimentos anormais). Nos experimentos, foram capturados sinais nos três eixos ortogonais x, y e z com alta relação sinal ruído, permitindo a extração de características de acordo com a metodologia adotada e o processamento com sucesso em todas as fases do estudo.

O algoritmo desenvolvido no Matlab para o processamento *off-line* dos dados capturados pelo acelerômetro foi eficaz na extração das principais características de dinâmica e postura, as quais foram representativas dos movimentos objetos de estudo e possibilitaram uma classificação final com altos índices de acerto. O procedimento de triangulação (parte do algoritmo), visando à extração de características dos sinais durante o processamento (parâmetros de dinâmica), pode ser aplicado a outros tipos de sinais, principalmente os casos aleatórios, onde a dificuldade de análise é mais complexa.

Não foi realizado um estudo sobre o potencial de discriminação de cada uma das características utilizadas na formação dos padrões para as categorias estudadas. Um aspecto importante a ser considerado em estudos futuros. Desta forma, pode-se eliminar ou acrescentar características mais significativas de modo a melhorar os índices de classificação.

Ao comparar os resultados obtidos com as duas arquiteturas de redes neurais, FAN e MLP, ilustrados na tabela 4 (primeiro experimento), com movimentos executados por diferentes indivíduos voluntários e sem um controle da intensidade, amplitude e frequência dos movimentos, o percentual de acerto no reconhecimento de padrões para a classe “tremores” foi de 100% para a rede neural FAN e 66% para a rede neural MLP. No entanto, para a classe “correndo”, no mesmo experimento, a rede neural FAN acertou 80% enquanto a rede neural MLP atingiu o índice de 95%. Observando-se os valores percentuais médios, os resultados obtidos com a rede neural FAN com índice de 81,6% de acerto, comparado com os 72,6% de acerto com a rede neural MLP, podem ser considerados significativos, principalmente pelas condições iniciais do experimento.

Com o aperfeiçoamento do *hardware* e a execução dos movimentos por um único indivíduo, houve uma melhora significativa comparando os resultados entre as duas redes neurais, tendo em vista que os movimentos foram regulados (controlados) durante a execução nos experimentos. A média percentual de acerto para a rede neural FAN foi de 98,2%, enquanto a rede neural MLP 96,7% (tabela 4).

Os valores percentuais de acerto para a classe “tremores”, foram de 99,2% para a rede neural FAN e 90,2% para a rede neural MLP. Para os outros movimentos (andando, correndo e palmas) a diferença percentual entre os valores obtidos para as duas redes neurais foi menor que 2%, sendo que o movimento “aceno de tchau” foi o único com acerto de 100%.

No terceiro experimento, foram incluídos mais 5 movimentos (penteando o cabelo, aparafusando, círculos na vertical com uma das mãos, socos no ar e coçando a perna) aumentando as regiões de sobreposição entre os movimentos (conflitos). Alguns testes realizados demonstraram uma diminuição significativa no índice de acerto (ver matriz de confusão apresentado pela rede neural FAN em resultados), principalmente entre os 5 últimos movimentos incluídos (aos movimentos dos experimentos anteriores). A solução encontrada foi a adição de 3 novas características na formação dos padrões para melhorar a performance na classificação final.

Com o aperfeiçoamento da metodologia adotada (3 novas características), além das características extraídas dos dados ligadas à frequência e amplitude dos movimentos (FFT, distâncias entre pontos de mínimo e máximo, áreas, perímetros), também passaram a ser considerados os valores de *offset* dos eixos x, y e z do acelerômetro, possibilitando um grande avanço na classificação, mesmo com movimentos muito semelhantes. Um exemplo de conflito que ocorreu entre dois tipos de movimentos estudados foi à execução de “círculos no ar com uma das mãos” e “aparafusando”, no entanto, como os mesmos foram executados em planos distintos, a principal diferença passa a ser a direção estática do membro em relação à aceleração da gravidade. Os resultados obtidos para a rede neural FAN e MLP foram surpreendentes, com índice de erro inferior a 1%, ou 99,3% e 99,1% respectivamente.

Os movimentos anormais constituem um único tipo de movimento e são simulações orientadas por um profissional da área médica: classe “tremores”. Os “tremores” estão relacionados com as contrações musculares (espasmos) que ocorrem nos casos graves de epilepsia e serão capturados em estudos futuros para a reclassificação dos dados. Os outros 9 movimentos do cotidiano (movimentos normais) são reais fortalecendo a realização desta pesquisa e os resultados obtidos. Os movimentos normais são relevantes neste estudo para a comparação dos

padrões com movimentos anormais, além de fornecer parâmetros importantes em estudos futuros com o monitoramento de atividades diárias (KHAN *et al.*, 2010).

O cálculo de um valor de “limiar” foi utilizado para se obter um controle sobre os pontos dos sinais capturados, eliminando somente os pontos de amplitudes não significativas, servindo como filtro destes pontos, além de permitir um ajuste individualizado dos movimentos realizados por diferentes pessoas. Nos estudos de Cuppens *et al.* 2007 e Cuppens *et al.* 2009 foram reduzidas várias janelas de dados não significativas para a detecção de crises de epilepsia (em torno de 80%). É importante observar que os valores calculados de “limiar”, foram ajustados de modo a interferir o mínimo possível no sinal original capturado pelo módulo de aquisição (ver tabela 1 no desenvolvimento do método). Na realidade, um valor de “limiar” terá mais importância, quando em estudos futuros, necessitar filtrar ou detectar movimentos remotos de tremores, quedas, atividades diárias e outros.

6.3 TRABALHOS FUTUROS

Em trabalhos futuros, pode-se verificar o desempenho do sistema proposto com outros métodos classificadores, tendo em vista que a base para a escolha do uso de redes neurais foram os excelentes resultados obtidos nas pesquisas de Khan *et al.* (2010), Santos *et al.* (2003), Zanchettin e Ludermir (2005) e Raittz (2002).

O *hardware* do módulo sensor e a placa de comunicação deverá evoluir para a comunicação sem fio (*wireless*), com a utilização de outros módulos sensores adaptados em pontos estratégicos, como nos pulsos, na cintura, no peito, pernas ou até mesmo nos bolsos da camisa ou das calças, como no estudo de Khan *et al.* (2004).

Na continuidade desta pesquisa, será realizada a captura de dados de pacientes (pediátricos) portadores de epilepsia no Hospital Pequeno Príncipe para atualizar o banco de dados com a classe “tremores”. Posteriormente, os dados deverão ser reprocessados para se obter uma classificação final. Alguns percentuais devem ser modificados em função de que, dificilmente uma simulação de tremores e espasmos será idêntica aos movimentos realizados durante uma crise real, apesar de todas as orientações recebidas de um especialista.

Em estudos futuros este método deverá ser utilizado para classificar outros tipos de tremores. Para alguns tipos de epilepsias como nas crises de ausência, provavelmente será necessário utilizar-se de outros modelos de sensores: como parâmetros de eletrocardiograma (ECG), eletromiograma (EMG), medição de fluxo sanguíneo, temperatura corporal e outros.

Outra forma de utilização do sistema desenvolvido pode ser o monitoramento remoto de pacientes com patologias graves. Nestes casos, o cálculo de um valor de “limiar” deverá eliminar movimentos não significativos (servindo como filtro) na detecção ou classificação de movimentos anormais, reduzindo significativamente o banco de dados armazenado (CUPPENS *et al.*, 2007; CUPPENS *et al.*, 2009; GIACOMOSSI *et al.*, 2011). No entanto, caso os movimentos sejam considerados normais e com intensidade suficiente para ultrapassar o “limiar” ajustado (ajuste individualizado), deve-se considerar o critério de um tempo mínimo de repetição destes movimentos para se evitar falsos positivos (BURCHFIELD e VENDATESAN, 2007). Com a utilização de redes neurais, uma vez realizado o treinamento ou aprendizado dos padrões representativos dos movimentos, o reconhecimento de um novo padrão é automático (RAITTZ, 2002). Sendo assim, basta instalar o *software* da rede neural em um telefone celular com recursos de memória e processador suficientes para o reconhecimento dos padrões desejados e posteriormente realizar uma chamada automática. Uma proposta interessante para pacientes que sofrem de epilepsias graves, idosos, gravidez de risco e outros.

REFERÊNCIAS

AGUIAR, F. G. **Utilização de redes neurais artificiais para detecção de padrões de vazamento em dutos**. 2010. 93 f. Dissertação (mestrado em engenharia mecânica), Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2010.

ANDRÉ, C. **O Guia Prático de Neurologia**. 1ª ed., Rio de Janeiro: Guanabara Koogan, 1999, p. 95.

ANGELO, M. F. S. D'; KIMO, Y. J. Estimativa de velocidade de motores de indução trifásicos do domínio do tempo, utilizando uma rede MLP treinada pelo algoritmo backpropagation. **Revista Unimontes Científica**, v. 2, n. 2, set. 2001.

BAIN, Peter. The mangement tremor. **Jornal of Neurology Neurosurg Psychiatry**. v.2. mar. 2002. Suppl 1. p. i3.

BABINI, M. **Reconhecimento de padrões lexicais por meio de redes neurais**. 2006. 108 f. Dissertação (mestre em engenharia elétrica), Faculdade de Engenharia de Ilha Solteira, UNESP (Campus de Ilha Solteira), Ilha Solteira, 2006.

BARBEAU, A. **Transtornos Del Movimiento**. Barcelona: Ediciones Toray, 1982.

BORGES, V.; FERRAZ H. B. Tremores. **Revista Neurociências**, São Paulo, v. 14, n. 1, p. 43-46, jan/mar. 2006.

BURCHFIELD, T. R.; VENDATESAN, S. Accelerometer-Based Human Abnormal Movement Detection in Wireless Sensor Networks. **Proceedings of the 1st ACM SIGMOBILE**, 2007, p. 67-69.

CAMBIER, J.; MASSON, M.; DEHEN, H. **Manual de neurologia**. 9. ed., Rio de Janeiro: Medsi, 1999. p.156-169.

CICHACZEWSKI, E.; CUNHA, J. C. da. Sistema computacional de auxílio ao diagnóstico e avaliação de tremores. **Memórias do XV Congresso Argentino de Bioingeniería**. 2005. p. 1-4.

COSME, L. B. **Tratamento de incertezas no projeto de sistemas de distribuição de energia elétrica: uma abordagem nebulosa**. 2011. 72 f. Dissertação (mestre em engenharia elétrica), Universidade Federal de Minas Gerais, Belo Horizonte, 2011.

CUPPENS, K.; OMLOOP, S.; COLLEMAN, P.; CEULEMANS, B.; VANRUMSTE, B.; KEMPEN, K. H. Detection of nocturnal epileptic seizures of pediatric patients using accelerometers: preliminary results. **Paper at IEEE Benelux EMBS Symposium**. 2007. 6-7 Dec.

CUPPENS, K.; LAGAE, L.; CEULEMANS, B.; HUFFEL, S. V.; VANRUMSTE, B. Detection of nocturnal frontal lobe seizures in pediatric patients by means of accelerometers: a first study. **Proceedings of 31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. 2009. 2-6 Sep.

DEUSCHL, G.; BAIN, P.; BRIN, M. Consensus Statement of the Movement Disorder Society on Tremor: Movement Disorders. In: Symposium on tremor in Kiel, Germany, v. 13, Supplement 3, 1998, p. 2-23.

ELEVANT, J. **Monitoring epilepsy with a wrist carried motion sensor**. 1999. 25 f. Tese. Home Care Technologies. Royal Institute of Technology. Department of Signals Sensors & Systems. Stockholm. 1999.

FERREIRA, F. V.; PRADO, A. L. C.; CIELO, C. A.; BUSANELLO, A. R. A relação da postura corporal com a prosódia na doença de Parkinson: estudo de caso. **Revista CFAC**, São Paulo, v. 9, n. 3, p. 319-329, jul-set. 2007.

FIGUEIREDO, L. J.; GAFANIZ A. R.; LOPES, G. S.; PEREIRA R. **Aplicações de acelerômetros**. 2007. 12 f. Monografia, Lisboa, Portugal, dez. 2007.

FONSECA, L. C.; TEDRUS, G. M. A.. Epilepsias parciais benignas da infância. In: MELO-SOUZA, S. E. de. **Tratamento das doenças neurológicas**. Rio de Janeiro: Guanabara Koogan, 2000. p. 420-423.

GRAHAM, B. B. **Using an accelerometer sensor to measure human hand motion**. 2000. 110 f. Requirements for the Degrees of Bachelor of Science in Electrical Science and Engineering and Master of Engineering in Electrical Engineering and Computer Science. Massachusetts Institute of Technology, 2000.

GALHARDO, I. **Propedêutica Neurológica Essencial**. São Paulo: Pancast, 1987. 151-157.

GARZON, E.; SAKAMOTO, A. C. Epilepsias do lobo temporal. In: MELO-SOUZA, S. E. de. **Tratamento das doenças neurológicas**. Rio de Janeiro: Guanabara Koogan, 2000. p. 433-437.

GIACOMOSSI, L. C.; PICHORIM, S. F. Classification of Normal and Abnormal Movements Captured by Accelerometer in Humans. In: INTERNATIONAL WORKSHOP ON BIOINFORMATICS, 1., 2010, Curitiba. **Anais eletrônicos...** p. 40.

GIACOMOSSI, L. C.; PICHORIM, S. F.; HIROZAWA, V. K.; MARTINS, L. D. L. Classificação de movimentos normais e anormais capturados por acelerômetro: resultados preliminares. V Latin American Congress of Biomedical Engineering, 2011, La Habana / Cuba. **IFMBE Proceedings**, 2011. v. 33. p. 1-4.

GIL, M. C. C. **Aplicação de Redes Neuro-Fuzzy para a Solução de Problemas Inversos em Transferência Radiativa**. 2010. 109 f. Tese. Universidade do Estado do Rio de Janeiro, Nova Friburgo, 2010.

GUERREIRO, C. A. M. Epilepsia tônico-clônica generalizada. In: MELO-SOUZA, S. E. de. **Tratamento das doenças neurológicas**. Rio de Janeiro: Guanabara Koogan, 2000. p. 444-446.

HAYKIN, S. **Redes Neurais: Princípios e práticas**. 2ª ed., Porto Alegre: Bookman, 2001.

HIROZAWA, V. K.; PICHORIM, S. F.; GIACOMOSSI, L. C. Desenvolvimento de um sistema telemétrico para monitoramento de tremores humanos. **Anais do Seminário de Iniciação Científica e Tecnológica da UTFPR**, 2010, p. 1-4.

JANKOVIC, J. Essential tremor: clinical characteristics. **Neurology**. 2000. v.54. suppl 4. p. s21-s25.

KUSTER, C. V.; IGNACIO, F. A.; LENFERS, F. P.; GARRETT, L. F. V.; ZOTTO, S. **EasyFan**. 2006. 176 f. Trabalho de Conclusão de Curso (Graduação em Tecnólogo em Informática), Universidade Federal do Paraná, Curitiba, 2006.

KHAN, A. M.; LEE, Y. -K.; LEE, S.; KIM, T. -S. Accelerometer`s position independent physical activity recognition system for long-term activity monitoring in the elderly. **Medical Biological Engineering Computing**. International Federation for Medical and Biological Engineering, p. 1271-1279. nov. 2010.

LERMONTOV, A.; YOKOYOMA, L.; LEMONTOV, M.; MACHADO, M. A. S. Aplicação da lógica nebulosa na parametrização de um novo índice de qualidade das águas. **Revista Engevista**. v. 10, n. 2, p. 106-125, dez. 2008.

LERMONTOV, A. **Novo índice de qualidade das águas com uso da lógica e interferência nebulosa**. Tese de Doutorado. 2009. 194 f. Tese de Doutorado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009.

LUDWIG JÚNIOR, O. **Análise comparativa entre métodos de reconhecimento de padrões aplicados ao problema gás-lift intermitente**. 2004. 74 f. Dissertação (mestrado em engenharia elétrica), Universidade Federal da Bahia, Bahia, 2004.

MARINO JUNIOR, R. **Epilepsias**: São Paulo: Savier, 1983. p. 1-16.

MARCHESI, B. **Deteção de padrões epileptiformes em sinais de eletroencefalografia através do paradigma da programação genética**. 1998. 133 f. Dissertação (mestrado em engenharia biomédica), Universidade Tecnológica Federal do Paraná, Curitiba, 1998.

MATHIE, M. J.; CELLER, B. G.; LOVELL, N. H.; COSTER, A. C. F. Classification of basic daily movements using a triaxial accelerometer. **Medical & Biological Engineering & Computing**, 2004, v. 42, n. 5, p. 679-687.

MARTINS, L. D. L.; PICHORIM, S. F.; GIACOMOSSI, L. C. Sensor telemétrico para monitoramento de tremores humanos: desenho do circuito e programação. **Anais do Seminário de Iniciação Científica e Tecnológica da UTFPR**, 2010, p. 1-4.

MATTOS, J. P. de. Diagnóstico diferencial dos tremores. **Associação Arquivo de Neuro-Psiquiatria**, São Paulo, v. 56, n. 2, jun. 1988.

MELO-SOUZA, S. E. de. **Tratamento das doenças neurológicas**. Rio de Janeiro: Guanabara Koogan, 2000. p. 417-484.

MOREIRA, E. de R.; NETO, G. T. **Avaliação funcional de pacientes com mal de Parkinson através do teste de caminhada de seis minutos**. Monografia (Graduação em Fisioterapia), Centro Universitário Claretiano, Batatais, 2007.

NETO, J. G.; MARCHETTI, R. L. Aspectos epidemiológicos e relevância dos transtornos mentais associados à epilepsia. **Revista Brasileira de Psiquiatria**. São Paulo, v. 27, n. 4, dec. 2005.

NIJSEN, T. M. E. **Accelerometry based detection of epileptic seizures**. 2008. 128 f. Tese. Technische Universiteit Eindhoven, set. 2008.

PAO, Y. H. **Adaptive pattern recognition and neural networks**. 1989. p. 3 - 79.

PERSAD, V.; THOMPSON, M. D.; PERCY, M. E. Epilepsy and developmental disability part I: developmental disorders in which epilepsy may be comorbidity. **Journal on Developmental Disabilities**, v. 10, n° 2, 2003, p. 123.

PORTUGUEZ, M. W. *et al.* Neuropsychological aspects of psychogenic nonepileptic seizures. **Journal Epilepsy and Clinical Neurophysiology**. Porto Alegre. 2007. p. 24-27.

RAGAZZO, P. C. Pequeno mal. In: MELO-SOUZA, S. E. de. **Tratamento das doenças neurológicas**. Rio de Janeiro: Guanabara Koogan, 2000. p. 430-432.

RAITZ, R. T. **Fan: Um modelo neuro-fuzzy para reconhecimento de padrões**. 2002. 88 f. Tese (Doutorado em Engenharia de Produção), Universidade Federal de Santa Catarina, Florianópolis, 2002.

ROLAK, L. A. **Segredos em Neurologia**. 2. ed., Porto Alegre: Artmed, 1995. 331-349.

SANTOS, A. M. dos; PEREIRA, B. de B.; SEIXAS, J. M. de; MELLO, F. C. de Q.; KRITSKI, A. L. Árvore de Classificação e Redes Neurais Artificiais: Uma Aplicação à Predição de Tuberculose Pulmonar. **Proceedings of the VI Brazilian Conference on Neural Networks**. 2003. 2-5 Jun.

VIEIRA, S. **Tremores**. Revista Portuguesa Clínica Geral 2005, p. 61-67.

WINTER, R. **Estudo sobre a medição do tremor humano utilizando acelerômetro piezoelétrico e processamento de sinais digitais**. 1999. 151 f. Dissertação (mestrado em engenharia biomédica), Universidade Tecnológica Federal do Paraná, Curitiba, 1999.

ZANCHETTIN, C.; LUDERMIR, T. B. Sistemas neurais híbridos para reconhecimento de padrões em narizes artificiais. **Revista Controle & Automação**. V. 16, n. 2, abr. mai. e jun. 2005.

